



**ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE**

---

**FAKULTA BIOMEDICÍNSKÉHO INŽENÝRSVÍ**  
**Katedra biomedicínské techniky**

**Porovnání vlivu odhadu výkonového spektra na  
extrakci neurálního korelátu změněných stavů  
vědomí během spánku**

**Comparison of the effect of power spectrum  
estimation on neural correlate extraction of altered  
states of consciousness during sleep**

Bakalářská práce

Studijní program: Biomedicínská a klinická technika

Studijní obor: Biomedicínský technik

Vedoucí práce: Ing. Marek Piorecký

**Natálie Svatková**

---

Kladno 2020



# ZADÁNÍ BAKALÁŘSKÉ PRÁCE

## I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Svatková** Jméno: **Natálie** Osobní číslo: **474270**  
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:

**Porovnání vlivu odhadu výkonového spektra na extrakci neurálního korelátu změněných stavů vědomí během spánku**

Název bakalářské práce anglicky:

**Comparison of the effect of power spectrum estimation on neural correlate extraction of altered states of consciousness during sleep**

Pokyny pro vypracování:

Implementujte metodiku frekvenční analýzy mozkové aktivity ve spánku pro 2 skupiny probandů rozdělených na základě subjektivního paradigmatu. Proveďte extrakci výkonového spektra pomocí vlnkové transformace a pomocí Fourierovy transformace. Statisticky porovnejte spektrální výkony na základě paradigmatu pro obě metody odhadu spektra. Výsledky odhadu spektra porovnejte s výsledky současných výzkumů.

Seznam doporučené literatury:

- [1] Francesca Siclari, Benjamin Baird, Lampros Perogamvros, Giulio Bernardi, The neural correlates of dreaming, Nature Neuroscience, ročník 20, číslo 6, 2017
- [2] Vinay K. Ingle, John G. Proakis, Digital signal processing using MATLAB, ed. Third edition, CENGAGE Learning, 2012, ISBN 978-1-111-42737-5
- [3] Krajča V., Mohylová J., Číslíkové zpracování neurofyziologických signálů, ed. 1st, ČVUT Praha, 2011, ISBN 9788001047217

Jméno a příjmení vedoucí(ho) bakalářské práce:

**Ing. Marek Piorecký**

Jméno a příjmení konzultanta(ky) bakalářské práce:

**Ing. Jan Štrobl, Bušková, Jitka, MUDr., Ph.D.**

Datum zadání bakalářské práce: **17.02.2020**

Platnost zadání bakalářské práce: **19.09.2021**

  
prof. Ing. Peter Kneppo, DrSc.  
podpis vedoucí(ho) katedry

  
prof. MUDr. Ivan Dylevský, DrSc.  
podpis děkana(ky)

## Prohlášení

Prohlašuji, že jsem bakalářskou práci s názvem „Porovnání vlivu odhadu výkonového spektra na extrakci neurálního korelátu změněných stavů vědomí během spánku“ 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 .....

.....

**Natálie Svatková**

## **Poděkování**

Ráda bych poděkovala vedoucímu mé bakalářské práce Ing. Marku Pioreckému za odborné vedení a skvělý přístup. Dále děkuji celému Brain teamu FBMI za věcné připomínky a rady.

## **ABSTRAKT**

### **Porovnání vlivu odhadu výkonového spektra na extrakci neuronálního korelátu změněných stavů vědomí během spánku**

Sen je nedílnou součástí spánku. Doposud zůstává tato mozková aktivita ne zcela pochopena. Snění může být spojeno s prožíváním silných negativních emocí a z toho vyplývajícími spánkovými potížemi. Nástroj, který by v EEG detekoval a charakterizoval snění, by mohl pomoci k pochopení mechanismu snění, diagnostice a následné léčbě některých poruch s ním spjatých. Cílem této práce je přispět k popisu charakteru snění v EEG datech. Analýzou 126 spánkových EEG záznamů s přítomností a nepřítomností snění pomocí krátkodobé Fourierovy transformace a vlnkové transformace bylo zjištěno, že snění je spojeno se zvýšením beta aktivity v parieto-okcipitální oblasti mozku se současným poklesem aktivity v delta pásmu. V alfa pásmu byl v průběhu snění zjištěn pokles aktivity v parieto-temporální oblasti. Snížený výkon v rámci snění pro pásmo alfa byl pozorovatelný také v centrální a frontální části mozku. Na základě provedení časově frekvenční analýzy pomocí dvou metod odhadu spektra byl v této práci popsán charakter snění v EEG datech na robustním datasetu.

### **Klíčová slova**

snění, časově frekvenční analýza, EEG

## **ABSTRACT**

### **Comparison of the effect of power spectrum estimation on neural correlate extraction of altered states of consciousness during sleep:**

A dream is an integral part of sleep. So far, this brain activity remains not fully understood. Dreaming can be associated with experiencing strong negative emotions and resulting sleep problems. A tool, that would be able to detect and characterize dreaming in the EEG, could help understanding the mechanism of dreaming and also could help with better treatment of some sleep disorders. The aim of this work is to contribute to the description of character of dreaming. By performing an analysis of 126 EEG sleep records with the presence and absence of dreaming using wavelet transform and short-time Fourier transform, was found that dreaming is associated with an increase of beta activity in parieto-occipital regions. The increase of beta activity in parieto-occipital regions was associated with decrease of delta activity. In alpha rhythm dreaming was associated with decrease activity in parieto-temporal regions. Reduced power in alpha rhythm was also observed in central and frontal parts of the brain. In this work the character of dreaming in EEG data was described on a robust dataset based on time-frequency analysis using two methods of spectrum estimation.

### **Key words**

dreaming, time-frequency analysis, EEG

# Obsah

Seznam symbolů zkratek . . . . .	8
<b>1 Úvod . . . . .</b>	<b>9</b>
<b>2 Přehled současného stavu . . . . .</b>	<b>10</b>
<b>3 Cíle práce . . . . .</b>	<b>11</b>
<b>4 Teoretická část . . . . .</b>	<b>12</b>
4.1 Elektroencefalografie . . . . .	12
4.2 Záznam EEG . . . . .	12
4.3 Artefakty . . . . .	13
4.4 Rytmy EEG . . . . .	14
4.5 Spánek . . . . .	15
4.6 Zpracování EEG . . . . .	16
4.6.1 Časově frekvenční analýza . . . . .	16
4.6.2 Fourierova transformace . . . . .	16
4.6.3 Krátkodobá Fourierova transformace . . . . .	17
4.6.4 Vlnková transformace . . . . .	18
4.6.5 Grafický výstup časově frekvenční analýzy . . . . .	20
<b>5 Metody . . . . .</b>	<b>23</b>
5.1 Analyzovaná data . . . . .	23
5.2 Předzpracování signálů . . . . .	24
5.3 Časově frekvenční analýza . . . . .	25
5.4 Statistické zhodnocení . . . . .	27
<b>6 Výsledky . . . . .</b>	<b>31</b>
6.1 Krátkodobá Fourierova transformace . . . . .	31
6.1.1 Alfa pásmo . . . . .	32
6.1.2 Beta pásmo . . . . .	33
6.1.3 Delta pásmo . . . . .	34
6.1.4 Theta pásmo . . . . .	35
6.2 Vlnková transformace . . . . .	37
6.2.1 Alfa pásmo . . . . .	38
6.2.2 Beta pásmo . . . . .	39
6.2.3 Delta pásmo . . . . .	40
6.2.4 Theta pásmo . . . . .	41
6.3 Přelévání výkonu mezi pásmy . . . . .	43
6.4 Porovnání vlivu odhadu výkonového spektra . . . . .	45

6.5	Zastoupení výkonu v parieto-okcipitální oblasti . . . . .	49
<b>7</b>	<b>Diskuse . . . . .</b>	<b>51</b>
7.1	Krátkodobá Fourierova transformace . . . . .	51
7.2	Vlnková transformace . . . . .	51
7.3	Přelévání výkonu mezi jednotlivými pásmy . . . . .	52
7.4	Porovnání metod odhadu spektra . . . . .	52
7.5	Porovnání výsledků se současnými výzkumy . . . . .	53
7.6	Limitace práce . . . . .	54
<b>8</b>	<b>Závěr . . . . .</b>	<b>55</b>
	<b>Seznam použité literatury . . . . .</b>	<b>56</b>
	<b>Příloha A: Zastoupení výkonu v jednotlivých pásmech . . . . .</b>	<b>59</b>
	<b>Příloha B: Obsah přiloženého CD . . . . .</b>	<b>63</b>



# Seznam symbolů a zkratek

## Seznam symbolů

Symbol	Jednotka	Význam
<i>PSD</i>	$\mu V^2/Hz$	Spektrální výkonová hustota

## Seznam zkratek

Zkratka	Význam
EEG	elektroencefalogram
iEEG	intrakraniální elektroencefalogram
NIRS	blízká infračervená spektroskopie
MEG	magnetoencefalografie
FIR	finite impulse response (konečná impulzní odezva)
STFT	krátkodobá Fourierova transformace
GT	Gaborova transformace
CMWT	kontinuální Morletova vlnková transformace
CWT	kontinuální vlnková transformace
HT	Hilbertova transformace
FFT	Rychlá Fourierova transformace
FT	Fourierova transformace
DFT	Diskrétní Fourierova transformace
CSA	zhuštěné spektrální kulisy
REM	rapid eye movement (rychlé pohyby očí)
NREM	no rapid eye movement (bez rychlého pohybu očí)
WT	wavelet transform (vlnková transformace)

# 1 Úvod

Spánek je stav organismu, kterým lidé stráví až třetinu svého života. Jedná se o ne zcela prozkoumanou oblast, která je charakteristická změnami v aktivitě mozku a ztrátou vědomí za běžných fyziologických podmínek. Při probuzení ze spánku někteří lidé udávají, že prožili zážitek, jiní prožitek v paměti nemají. Ve spánku tedy můžeme nebo nemusíme prožívat zkušenosti s různou tematikou a emočním laděním. Proud těchto zkušeností během spánku nazýváme snění.

Sny mohou mít mnoho různých forem od realistických a teoreticky možných až po noční můry a děsy. Noční můry, které jsou charakteristické pocitem strachu a úzkosti, se vyskytují týdně u 4–10 % celkové populace. Pravidelný a dlouhodobý výskyt nočních můr může způsobit psychické problémy a strach ze spánku. Nedostatek spánku pak může být příčinou nejen zhoršené fyzické výkonnosti jedince a jeho podrážděnosti, ale i mnoha vážných zdravotních potíží. [1]

Výzkum spánku se provádí pomocí elektroencefalografie. Tato diagnostická metoda umožňuje zaznamenat elektrickou aktivitu mozku elektrodami rozmístěnými na pokožce hlavy. Dosavadní studie zatím neobjasnily účel ani význam snů. Lepší prozkoumatelnost snění by tedy mohla pomoci k pochopení účelu snů a možná také k objasnění další části lidského podvědomí. Výzkum snění by mohl také přispět k efektivnější léčbě spánkových poruch, jako jsou např. noční můry a děsy, a k předcházení zdravotních potíží způsobených spánkovou deprivací.

## 2 Přehled současného stavu

Dříve bylo snění spojováno pouze s REM (rapid eye movement) fází spánku. Předpokládalo se, že vysokofrekvenční aktivita REM spánku je spojena s přítomností snů, zatímco nízkofrekvenční aktivita NREM (no rapid eye movement) spánku je spojena s absencí snění. Pozdější studie ukázaly, že ke snění může docházet v obou fázích spánku. Zprávy o snu byly v obou fázích spánku spojeny s místním poklesem nízkofrekvenční (1–4 Hz) aktivity v zadních kortikálních oblastech mozku. Místní zvýšení nízkofrekvenční aktivity v těchto oblastech bylo naopak spojeno s neexistencí zkušenosti. Vysokofrekvenční aktivita (20–50 Hz) v zadních kortikálních oblastech byla spojena se specifickým obsahem snů. [2]

K rozšíření těchto poznatků se další studie zabývala specifickými rysy pomalých vln a vřeten souvisejících se sněním v NREM spánku. Bylo zjištěno, že zprávám o snění ve srovnání se zprávami o žádné zkušenosti předcházelo méně menších a mělčích pomalých vln a rychlejších vřeten. Tyto změny byly pozorovatelné zejména ve středních a zadních kortikálních oblastech mozku. Také byla identifikována malá skupina velmi strmých a velkých pomalých vln v čelních oblastech spojená se zvýšením vysokofrekvenčního výkonu. Úspěšné vyvolání obsahu snů bylo spojeno s nárustem vysokofrekvenční aktivity. [3]

V další studii zkoumající elektrofyziologické koreláty snění v NREM spánku [4] autoři zjistili, že vzpomínky na sen jsou spojeny se snížením delta aktivity během posledního segmentu spánku. Snížení delta aktivity se vyskytovalo v levé frontální a temporoparietální oblasti. [4]

Autoři publikace [5] uvedli elektroencefalografické koreláty snění. Vznik snění byl během přechodu do spánku spojen se zvýšením absolutního výkonu pod 7 Hz. V druhé fázi NREM spánku bylo snění spojeno se snížením relativního výkonu pod 1 Hz. V této fázi spánku bylo snížení nízkofrekvenčního výkonu doprovázené zvýšením relativního výkonu nad 4 Hz. Během REM spánku nebyly zjištěny žádné prediktory snění. [5]

Studie potvrdily, že snění je doopravdy zážitek, který se objevuje během spánku. Dříve mnoho vědců zastávalo názor, že snění je pouze něco, co si lidé vymyslí při probuzení. Ukazuje se, že mozek při snění a mozek při vědomí jsou si podobnější, než jsme předpokládali. Mozek v těchto dvou stavech částečně využívá podobné oblasti pro stejný typ zážitků. [2]

### 3 Cíle práce

Cílem této bakalářské práce je přispět k popisu charakteru snění v EEG datech. Bude provedena analýza spánkových EEG záznamů pomocí dvou metod odhadu spektra pro dvě skupiny probandů rozdělených na základě subjektivního paradigmatu. V této práci budou využity metody časově frekvenční analýzy: vlnková transformace a krátkodobá Fourierova transformace. Oproti současným studiím tato práce obsahuje velký datový soubor. Je zde analyzováno celkem 126 spánkových záznamů rozdělených podle přítomnosti a nepřítomnosti snění v průběhu spánku. Pro obě metody odhadu spektra budou statisticky porovnány spektrální výkony mezi skupinami. Získané výsledky budou následně srovnány s výsledky nejnovějších studií.

Výsledky bakalářské práce by mohly pomoci v klinické praxi a také přispět k porozumění mechanismu snů. V klinické praxi se jedná zejména o léčbu a pochopení spánkových patologií. Tyto patologie mohou být způsobeny prožíváním silných negativních emocí během spánku a mohou vést ke spánkové deprivaci. Nedostatek spánku pak může být příčinou vážných zdravotních potíží. Vyšší prozkoumatelnost snění by tedy mohla přispět k cílené a efektivnější léčbě pacientů trpících spánkovými potížemi, jako jsou např. noční můry a děsy.

## 4 Teoretická část

Tato kapitola obsahuje celkem šest podkapitol. Je zde postupně popsána problematika elektroencefalografie, dále se tato kapitola zabývá elektroencefalografickým záznamem (EEG), artefakty, základními EEG rytmy, spánkem a metodami zpracování signálů v časově frekvenční oblasti včetně možností interpretace výsledků.

### 4.1 Elektroencefalografie


Elektroencefalogram je záznam elektrické aktivity mozku. Jedná se o kvazi-stacionární signál, který může obsahovat důležité informace o stavu mozku. V současné době je elektroencefalografie jedna ze základních metod pro diagnózu neurologických poruch a jiných abnormalit souvisejících s činností mozku. Využívá se ke zkoumání následujících klinických problémů: [6, 7]

- sledování bdělosti, bezvědomí a smrti mozku
- zkoumání epilepsie a lokalizace původu záchvatů
- vyšetřování psychiatrických poruch
- lokalizace oblasti poškození při poranění hlavy, nádoru a mrtvici
- testování aferentních drah (podle evokovaných potenciálů)
- zkoumání poruch spánku
- sledování vývoje mozku

### 4.2 Záznam EEG

EEG se zaznamenává pomocí elektrod umístěných na pokožce hlavy. Jedná se tedy o neinvazivní metodu, která při ambulantním vyšetření trvá kolem dvaceti minut. V některých případech je nutné dlouhodobé monitorování, které může trvat až několik desítek hodin. Existují dva typy snímání EEG. Unipolární zapojení, které snímá aktivitu mezi referenční a aktivní elektrodou. Referenční elektroda je nejčastěji umístěna na ušním lalůčku. U bipolárního zapojení se měří rozdíl potenciálů mezi dvěma aktivními elektrodami. Běžně se k vyšetření využívá 18–20 kanálů (maximálně 256 kanálů). Povrchové elektrody jsou umístěny v systému 10–20 (deset-dvacet). Systém je založen na vztahu mezi umístěním elektrod a základní oblastí mozkové kůry. Vzdálenost mezi sousedními elektrodami je rovna 10 % nebo 20 % délky povrchu hlavy. Elektrody se značí podle příslušné části hlavy: C – centrální,


P – parietální, F – frontální, O – okcipitální, T – temporální. Sudá čísla označují, že je elektroda umístěna nad pravou hemisférou, lichá čísla nad levou hemisférou. Obrázek 4.1 zobrazuje mezinárodní systém 10-20. [6, 8]



Obrázek 4.1: Elektrody v systému 10-20, převzato z [9]

### 4.3 Artefakty

Zaznamenaný EEG signál obsahuje kromě základních EEG rytmů také artefakty, v některých případech i grafoelementy. Artefakty jsou nežádoucí signály, které nemají původ ve zkoumané části těla. Rozlišujeme artefakty technické (fyzikální) a biologické. Jelikož elektroencefalografický záznam dosahuje velice malých amplitud, je vysoce citlivý na artefakty. Pro správnou interpretaci signálů musí být artefakty správně detekovány. Mezi nejčastější artefakty patří: síťový brum 50 Hz, vliv špatné elektrody (kolísání isolinie, ztráta kontaktu), svalové artefakty, pocení pacienta, mrkání nebo oční pohyby. Obrázek 4.2 zobrazuje některé druhy artefaktů. [6, 8, 10]



Obrázek 4.2: Artefakty, převzato z [10]

## 4.4 Rytmy EEG


Frekvenční rozsah EEG záznamu se pohybuje v rozmezí od 0,5 Hz do 80 Hz (v některých případech až do 150 Hz). Na základě frekvence rozlišujeme čtyři hlavní frekvenční pásma pro diagnózu: delta, theta, alfa a beta. Tato čtyři základní pásma se pohybují ve frekvenčním rozsahu od 0,5 Hz do 30 Hz. Obrázek 4.3 zobrazuje jednotlivá základní EEG pásma.

### Delta rytmus

Delta rytmus odpovídá frekvencím v rozmezí 0,5–4,0 Hz. V bdělém stavu se u dospělých osob jedná o abnormalitu. Primárně je spojen s hlubokým spánkem. Vyskytuje se v tranzu a hypnóze. U dospělých osob může indikovat nádory. U dětí starších několik měsíců je základní rytmus 4 Hz. [6, 10]

### Theta rytmus

Theta aktivita se pohybuje v rozmezí frekvencí 4,0–7,5 Hz. Amplituda do 30  $\mu\text{V}$  neznačí patologický stav. Pokud je amplituda theta vln alespoň dvakrát vyšší než u alfa vln, jedná se o abnormalitu. U zdravých jedinců se theta vlny objevují nad temporální krajinou, v centrální a parietální oblasti. [6, 10]



Obrázek 4.3: Jednotlivé EEG aktivity, převzato z [7]

### Alfa rytmus


Alfa aktivita obsahuje frekvence v rozmezí 8,0–13,0 Hz. Vyskytuje se u zdravých jedinců při zavřených očích, tlumí se duševní činností a otevřením očí. Tento rytmus je charakteristický pro stadium před usnutím. [6, 10]

## Beta rytmus

Beta rytmus představuje frekvence v rozmezí 14,0–30,0Hz. Je dominantní nad frontálními laloky. Tento rytmus je typický pro soustředění, aktivní myšlení a řešení konkrétních problémů. [6, 10]

## 4.5 Spánek

Spánek je stav organismu, který je charakteristický sníženou schopností reakce na vnější podněty, snížením pohybů těla, zvýšenou rychlostí anabolismu (syntéza buněčných struktur) a sníženou rychlostí katabolismu (rozklad buněčných struktur). Dříve byl spánek považován za pasivní stav. Nyní chápeme spánek jako dynamický proces. Rozlišujeme dva typy spánku: REM (rapid eye movement) a NREM (no rapid eye movement). NREM spánek se dále dělí do 4 fází [7]. Spánkový cyklus se skládá z fází NREM spánku, po kterých přichází REM spánek. Celý cyklus trvá přibližně 60–90 minut. Obrázek 4.4 ukazuje EEG záznam v různých úrovních vědomí. [7]



Obrázek 4.4: EEG aktivita během různých úrovní vědomí, převzato z [9], upraveno

## REM spánek

REM spánek se vyskytuje 4–5 krát během noci a zaujímá 20–25 % celkové doby spánku. Je charakteristický rychlým pohybem očních bulv, zrychleným dechem a srdeční frekvencí, zvýšeným krevním tlakem a nízkým svalovým napětím. Mozek je během REM spánku vysoce aktivní. EEG aktivita je podobná aktivitě zaznamenané během bdění. [7]



## NREM spánek

Fáze I je fází ospalosti a lehkého spánku. Během této fáze se oční bulvy pomalu pohybují a dochází k uvolňování svalů. Fáze II představuje 40–50 % celkové doby spánku. V této fázi je pohyb očí zastaven. V EEG aktivitě převládají pomalé frekvence (0,7–4 Hz). Ve fázi III se subjekt dostává do hlubokého spánku. Začínají se objevovat delta vlny. Fáze IV je charakteristická delta aktivitou. Mezi fázemi III a IV nejsou velké rozdíly, liší se pouze procentuálním zastoupením aktivity delta. Během těchto dvou fází nedochází k pohybu svalů a očí. [7]

## 4.6 Zpracování EEG

V současné době probíhá záznam EEG výhradně na digitálních přístrojích. V těchto přístrojích se signál zesiluje, převádí do číslicového tvaru a filtruje. Digitální podoba signálu nám umožňuje mnoho různých metod následného zpracování signálů, jako je např. automatická klasifikace, výpočet koherence mezi svody, brain mapping nebo také časově frekvenční analýza. [6, 10]

### 4.6.1 Časově frekvenční analýza

Elektroencefalografický signál je charakterizován časově proměnnými vlastnostmi signálu. Ze statistického hlediska se jedná o nestacionární signál (statistické vlastnosti se liší v závislosti na čase). V těchto případech je výhodné použít časově frekvenční analýzu. Tato metoda udává informaci o časovém výskytu frekvenčních složek v signálu. K odhadu spektra biologických signálů jsou nejčastěji používané techniky: krátkodobá Fourierova transformace (SFTF), Gaborova transformace (GT), Morletova vlnková transformace (CMWT) a Hilbertova transformace (HT). [11, 12]

### 4.6.2 Fourierova transformace

Fourierova transformace (FT) je ortogonální transformace, která přiřazuje časovému průběhu signálu spektrum a naopak [6]. Jedná se o neparametrickou metodu frekvenční analýzy. Význam Fourierovy transformace prudce vzrostl s objevem rychlé Fourierovy transformace (FFT), která výrazně redukuje výpočetní náročnost. V současné době pracujeme se signály v digitální podobě, z tohoto důvodu je pro nás důležitá zejména diskretní Fourierova transformace. Přímá diskretní Fourierova transformace je definována takto:

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi kn}{N}}, k = 0, 1, \dots, N-1 \quad (4.1)$$

Inverzní diskrétní Fourierova transformace je definována takto:


$$x(n) = \frac{1}{N} \sum_{k=0}^{N-1} X(k) e^{j \frac{2\pi kn}{N}}, k = 0, 1, \dots, N - 1 \quad (4.2)$$

kde  $x(n)$  je původní signál a  $X(k)$  je Fourierovo spektrum. [6]

Fourierova transformace využívá předpokladu, že každý periodický signál je složen ze součtu jednotlivých sinusovek a kosinusovek s určitou frekvencí a amplitudou. Frekvenční spektrum (periodogram) tedy získáme překreslením frekvencí a jejich amplitud do grafu. Při výpočtu Fourierovy transformace jsme omezeni intervalem pozorování, z tohoto důvodu musíme signál periodicky rozšířit. Zvolení intervalu pozorování je, jako kdybychom původní signál vynásobili okénkem. [6]

### 4.6.3 Krátkodobá Fourierova transformace

Nevýhodou Fourierovy transformace je, že poskytuje pouze frekvenční rozlišení a žádné časové. Jednou z metod řešení tohoto problému je krátkodobá Fourierova transformace (SFTF). Princip krátkodobé Fourierovy transformace zobrazuje následující obrázek 4.5. [6, 12, 13]



Obrázek 4.5: Princip Krátkodobé Fourierovy transformace, převzato z [13]

Krátkodobá Fourierova transformace je jedna z nejčastěji používaných technik k odhadu spektra biologických signálů. Fourierova transformace předpokládá periodický signál. EEG tento předpoklad nesplňuje, proto výpočet provádíme na krátkých úsecích, kde předpokládáme periodicitu. Při výpočtu je signál rozdělen na segmenty. Každý segment je vynásoben symetrickým okénkem a následně převeden do spektra

pomocí Fourierovy transformace. Okénko se postupně posouvá po signálu s daným krokem. Může docházet i k částečnému překryvu okének. [6, 12, 13]

Při výpočtu SFTF můžeme využít okénka s pevnou nebo proměnnou délkou. Pevná délka okénka je nezávislá na frekvenci. Při proměnné délce okénka se okénko zmenšuje se zvyšující se frekvencí. Cílem zúžení je omezit spektrální únik a řídit vyhlazování frekvence. Frekvenční rozlišení je závislé na délce okénka a je definováno jako  $1/\text{délka okénka}$  v sekundách. Při délce okénka 2 s tedy dosáhneme frekvenčního rozlišení 0,5 Hz. Časově široké okénko nám poskytne velké frekvenční rozlišení. Naopak čím větší je zvolená délka okénka, tím horší je časové rozlišení. K výpočtu můžeme použít několik druhů okének, jako např. obdélníkové, Barlettovo, Hanningovo, Hammingovo, Blackmanovo a Tukeyovo okénko. [6, 14]

#### 4.6.4 Vlnková transformace


Pevná délka okénka u krátkodobé Fourierovy transformace nám neumožňuje současně dosáhnout velkého rozlišení v čase i frekvenci. V celé časově frekvenční doméně je dosaženo pevného rozlišení. Tento problém se snaží vyřešit vlnková transformace. Vlnková transformace využívá širokého okna v nízkofrekvenčním rozsahu a úzkého okna ve vysokofrekvenčním rozsahu. Adaptivních oken a flexibilního časového rozlišení je dosaženo pomocí vlnek, které jsou základem principu vlnkové transformace. Vlnky jsou vytvářeny z jediné mateřské vlnky  $\psi(t)$  pomocí posunu a změny měřítka:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right), a \in \mathbb{R}^+, b \in \mathbb{R}, a \neq 0 \quad (4.3)$$

kde  $a$  je parametr měřítka a  $b$  je parametr posunu, který označuje o kterou oblast se jedná. [15, 16]

Z hlediska Heisenbergova principu nejistoty však nemůžeme znát přesnou hodnotu frekvence a zároveň přesný čas výskytu této frekvence v čase. Signál tedy nemůže být reprezentovaný jako bod v časově frekvenčním prostoru. Myšlenkou vlnkové transformace je vhodnou změnou vlnky dosáhnout optimálního rozlišení v čase a frekvenci. [15, 16]

Následující obrázek 4.6 zobrazuje různé časově frekvenční rozlišení pro různé metody odhadu spektra. Je zde vidět pevné časově frekvenční rozlišení pro STFT a adaptivní rozlišení pro CWT. CWT dosahuje vysokého frekvenčního rozlišení v nízkofrekvenčním rozsahu a vysokého časového rozlišení ve vysokofrekvenčním rozsahu.



Obrázek 4.6: Časově frekvenční rozlišení pro STFT (vlevo) a CWT (vpravo)

Princip vlnkové transformace spočívá v porovnání signálu s vlnkou. Koeficienty vlnkové transformace se vypočítají podle vzorce:

$$c(a, b) = \int f(t)\psi_{a,b}^*(t)dt \quad (4.4)$$

kde \* značí komplexně sdruženou funkci,  $a$  měřítko a  $b$  posuv. Koeficienty vlnkové transformace udávají lokální míru podobnosti signálu s vlnkou pro určité měřítko a posuv. Při korelaci signálu s vlnkou je získána vysoká hodnota transformace, pokud signál s vlnkou nekoreluje, je získána nízká hodnota transformace. Při výpočtu se vlnka postupně posouvá po signálu a pro každý posuv je vypočítána podobnost signálu s vlnkou. Následně se tento proces opakuje pro různá měřítka. [15, 16]

Nejčastěji využívané vlnky jsou: Haar, Mayer, Morlet a Daubechies vlnky. Abychom však mohli použít funkci jako vlnku, musí splňovat následující vlastnosti. [17]

**Podmínka nulové střední hodnoty:**

$$\int_{-\infty}^{\infty} \psi(t)dt = 0 \quad (4.5)$$

**Podmínka přípustnosti:**


$$C\psi = \int_0^{\infty} \frac{|\Psi(\omega)|^2}{\omega} d\omega < \infty \quad (4.6)$$

kde  $\Psi(\omega)$  je Fourierova transformace mateřské vlnky  $\psi(t)$ .

**Podmínka konečné energie:**

$$E = \int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (4.7)$$

Obrázek 4.7 zobrazuje dva způsoby manipulace s vlnkami. Vlnku lze posouvat po signálu (obrázek 4. 7 (b)) a měnit její měřítko (obrázek 4. 7 (c)). [17]

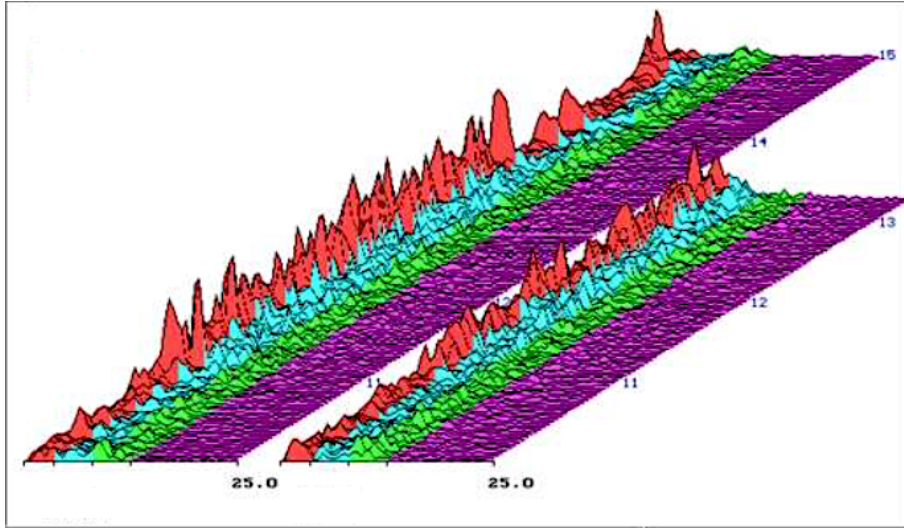


Obrázek 4.7: Posuv (b) a změna měřítka vlnky (c), upraveno, převzato z [17]

#### 4.6.5 Grafický výstup časově frekvenční analýzy

Vizualizaci časově frekvenční analýzy můžeme provést několika způsoby. Nevýhodou těchto zobrazení je, že přicházíme o informaci časového tvaru signálu při transformaci do frekvenční oblasti. Mezi způsoby vizualizace výstupu časově frekvenční analýzy patří: metoda zhuštěných spektrálních kulis (CSA), spektrogram (nebo škálogram) a topografické mapování. [6]

Metoda spektrálních zhuštěných kulis (CSA) využívá výpočtu frekvenčních křivek z krátkých úseků, které jsou následně seřazeny za sebou. Výsledek je tedy zobrazen pomocí pseudo-trojrozměrné projekce ( $f$ ,  $t$ ,  $\text{PSD}(f)$ ). Na ose  $x$  jsou zobrazeny jednotlivé frekvence. Osa  $y$  představuje výkonovou spektrální hustotu a osa  $z$  představuje jednotlivé časové okamžiky. Následující obrázek 4.8 ukazuje vizualizaci pomocí metody CSA, kde jsou jednotlivá pásma barevně odlišená. [6]



Obrázek 4.8: Metoda zhuštěných spektrálních kulis, upraveno, převzato z [6]

Další možností grafického výstupu časově frekvenční analýzy je zobrazení pomocí barevného grafu (spektrogram). Na ose  $x$  jsou zobrazeny jednotlivé časové okamžiky, osa  $y$  představuje jednotlivé frekvence a spektrální výkonová hustota je zde reprezentována pomocí barevné škály. Spektrogram zobrazuje obrázek 4.9. [14]

Spektrogram  $SP_s(t, f)$  zobrazující spektrální výkonovou hustotu je definován jako


$$SP_s(t, f) = |STFT_s(t, f)|^2 \quad (4.8)$$

kde

$$STFT_s(t, f) = \int_{-\infty}^{\infty} s(\tau)\omega(\tau - t)e^{-j2\pi f\tau} d\tau \quad (4.9)$$


STFT je krátkodobá Fourierova transformace signálu  $s(t)$  a  $\omega(\tau)$  je funkce okénka. [18]

Spektrogram je výstup časově frekvenční analýzy provedené pomocí krátkodobé Fourierovy transformace. U vlnkové transformace je výstup časově frekvenční analýzy pomocí barevného grafu nazýván škálogram. Škálogram obsahuje na ose  $x$  posuv  $b$  a na ose  $y$  měřítko  $a$ . Parametr  $a$  je nepřímo úměrný frekvenci. Pro vysoké frekvence tedy využíváme malý parametr  $a$ , zatímco pro nízké frekvence využíváme vysokou hodnotu parametru  $a$ . [15]



Obrázek 4.9: Spektrogram, upraveno, převzato z [19]

Topografické mapování patří k dalším způsobům vizualizace výsledků analýzy EEG signálu. Brain mappingem zjišťujeme plošné projevy mozkové aktivity. Hodnoty spektrální výkonové hustoty jsou zde zakódovány do barevné škály. Zbylé hodnoty, kde nebyl signál naměřen, jsou vypočítány jako průměr čtyř sousedních hodnot. Topografické mapování můžeme využít také pro mapování amplitudy, frekvence, koherence nebo kordance. Obrázek 4.10 zobrazuje topografickou reprezentaci výkonu. [6]



Obrázek 4.10: Topografická reprezentace výkonu, upraveno, převzato z [14]

## 5 Metody

Předzpracování dat, časově frekvenční analýza a statistické zpracování bylo provedeno v programovém prostředí MATLAB R2015b za využití knihovny FieldTrip a Statistical analysis. Knihovna FieldTrip umožňuje předzpracování a pokročilé metody analýzy signálů, jako je např. časově frekvenční analýza. Je určen pro MEG, EEG, iEEG a NIRS. [20]

MATLAB je programovací prostředí primárně určené pro matematické účely, které pracuje s daty formou matic. Je využíváno miliony vědců a inženýrů po celém světě v soukromém i akademickém sektoru. Pomocí MATLABU je možné analyzovat data, vyvíjet vlastní algoritmy a také vytvářet modely a aplikace. [21]

### 5.1 Analyzovaná data

Použitá data byla naměřena v Národním ústavu duševního zdraví a byla schválena Etickou komisí Národního ústavu duševního zdraví. Jedná se celkem o 155 spánkových EEG záznamů naměřených u 31 probandů. U každého probanda bylo naměřeno celkem 5 záznamů. Probandi byli během noci probuzeni v druhé fázi NREM spánku a tázáni, zda prožili sen. Odpověď byla vybrána z pěti uvedených možností: ano, spíše ano, nevím, spíše ne a ne. Pro analýzu spánkových záznamů byly vybrány pouze záznamy od subjektů, které odpověděly *ano* nebo *ne*. Z celkových 155 záznamů bylo u 55 záznamů zapsána odpověď *ano*. Odpověď *ne* byla zaznamenána celkem u 71 záznamů. Zbýlých 29 záznamů bylo vyloučeno. Vyloučení bylo provedeno, pokud proband nespál, pokud se při nahrávání vyskytly technické problémy nebo pokud si probandi nebyli jisti, zda prožili/neprožili sen.

Tabulka 5.1: Analyzované záznamy


Skupina	Počet	Zkratka
Přítomnost snu	55 (35,5 %)	ANO
Nepřítomnost snu	71 (45,8 %)	NE
Vyloučeno	29 (18,7 %)	-

Záznamy byly prováděny na přístroji BrainScope pomocí čepice s 21 elektrodami vůči zemi. Elektrody byly umístěny v systému 10-20, kde místo elektrod A1 a A2 (ušní boltce) byly použity elektrody M1 a M2 (processus mastoideus). Oproti standardnímu rozložení elektrod 10-20 byl využit i kanál AFz. Skórování bylo provedeno ve spánkové montagi. Spánková montáž využívá přepočtení vůči mastoideům.



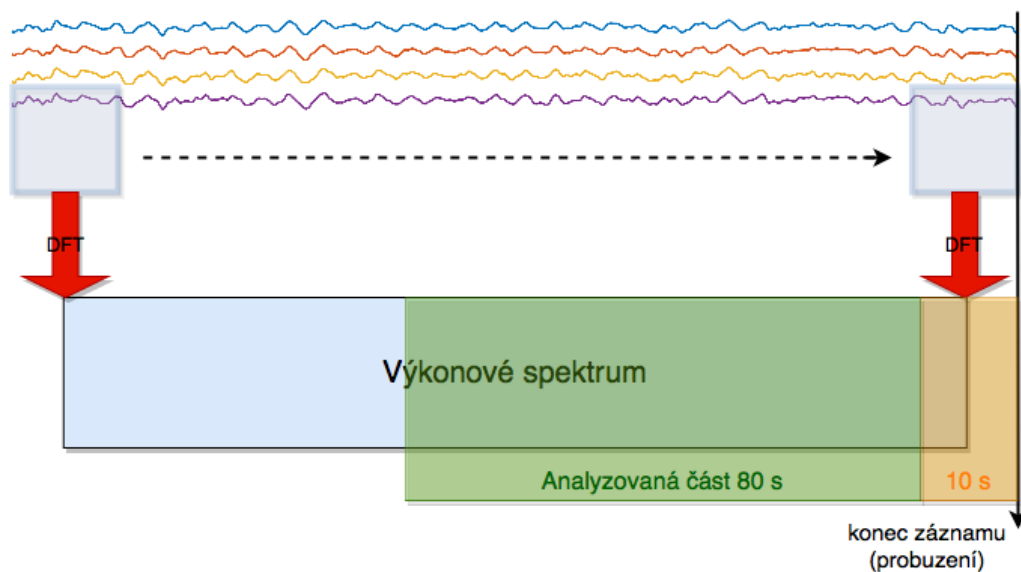
## 5.2 Předzpracování signálů

Signály byly vzorkovány vzorkovací frekvencí 250 Hz. Elektrody s označením M1 a M2 byly využity jako referenční elektrody. Jedná se o elektrody umístěné na processus mastoideus. Filtrace byla provedena pomocí FIR filtrů typu dolní a horní propust. Tento typ filtrů je vždy stabilní a vyznačuje se lineární fázovou charakteristikou [6]. Mezní frekvence byly nastaveny u dolnoproputního filtru na 40 Hz, u hornoproputního na 0,3 Hz. Bylo využito také filtru na posun izolinie. Následující obrázek 5.1 zobrazuje zpracovávaný EEG signál.



Obrázek 5.1: Ukázka zpracovávaného EEG signálu

Po předzpracování signálů byla u každého záznamu provedena extrakce výkonového spektra pomocí krátkodobé Fourierovy transformace a pomocí vlnkové transformace pro frekvence v rozsahu od 0,5 Hz do 30 Hz. Pro následné statistické vyhodnocení byl využit výstup z časově frekvenční analýzy z 80 sekund dlouhého časového intervalu. Následující obrázek 5.2 zobrazuje, jak byla provedena časově frekvenční analýza pomocí krátkodobé Fourierovy transformace. Část záznamu, která byla využita pro statistické zpracování a vyhodnocována, je zvýrazněna pomocí zelené barvy. Pro stejný časový úsek bylo provedeno vyhodnocení i u vlnkové transformace.




Obrázek 5.2: Analyzovaná část záznamů

### 5.3 Časově frekvenční analýza

Výpočet časově frekvenční reprezentace efektivních hodnot výkonu krátkodobou Fourierovou transformací byl proveden pomocí posuvného okna s fixní délkou nezávislou na frekvenci. Jednalo se konkrétně o Hanningovo okno o délce 2 s. Bylo tedy dosaženo rozlišení 0,5 Hz. Okénko se postupně posouvalo po signálu s krokem dlouhým 1 s. Okénka se tedy z 50 % překrývala. Překryv okénkových segmentů byl zvolen z důvodu kompenzace útlumu signálu na okrajích okénka. Analýza byla provedena pro všechny kanály. Oknovací funkce Hanningova okna je: [22, 23]

$$w(n) = \frac{1}{2} \left( 1 - \cos \frac{2\pi n}{N} \right) \quad (5.1)$$

Při výpočtu STFT dochází ke konvoluci Fourierovy transformace okénka se skutečným spektrem signálu. Vlivem konvoluce dochází k vyhlazování frekvence a spektrálnímu úniku. Vyhlazování frekvence je zapříčiněno šířkou hlavního laloku Fourierovy transformace okénka a způsobuje ztrátu spektrálního rozlišení. Spektrální únik je způsobený postranními laloky, které vedou ke ztrátě slabých složek signálu. Z těchto důvodů je důležité vybrat optimální okénko. Pro tuto práci bylo zvoleno Hanningovo okno, které poskytuje určitý kompromis. Na následujícím obrázku 5.3 je zobrazeno porovnání obdélníkového a Hanningova okénka. Hanningovo okénko nedosahuje tak velkého spektrálního rozlišení. Jeho výhodou jsou výrazně menší postranní laloky oproti obdélníkovému okénku (obrázek 5.3 vpravo).



Obrázek 5.3: Obdélkové okénko (plná čára) a Hanningovo okénko (přerušovaná čára) vlevo a jejich Fourierova transformace vpravo, převzato z [24]

Extrakce výkonového spektra pomocí vlnkové transformace byla provedena za využití Morletovy vlnky o šířce vlnky 10 (v počtu cyklů). Morletova vlnka je definována jako součin složité sinusové vlny a Gaussova okna:

$$w = e^{2i\pi ft} e^{-\frac{t^2}{2\sigma^2}} \quad (5.2)$$

kde  $i$  je imaginární jednotka,  $f$  frekvence v Hz a  $t$  je čas v s.  $\sigma$  je šířka Gaussova okna, která je definována takto:

$$\sigma = \frac{n}{2\pi f} \quad (5.3)$$

kde  $n$  je počet cyklů. Analýza byla provedena pro stejný rozsah frekvencí jako u STFT (od 0,5 Hz do 30 Hz). Posuv vlnky byl nastaven s krokem 1 s. [25]

Pro lepší porovnatelnost a interpretaci výsledků byly absolutní efektivní hodnoty výkonu přepočítány na relativní hodnoty. Následující algoritmus 1 popisuje princip přepočtu na relativní hodnoty.

**Data:** Absolutní efektivní hodnoty výkonu

**Výsledek:** Relativní efektivní hodnoty výkonu

**for**  $i = 1 : 1 : \text{počet kanálů}$  **do**

Absolutní efektivní hodnoty výkonu ve 3D matici:  $a = (\text{kanál} \times \text{frekvence} \times \text{čas})$ ;

Výběr jednoho kanálu:  $data = (\text{frekvence} \times \text{čas})$ ;

Součet přes frekvence:  $soucet = \text{sum}(data, 1)$ ;

Každý řádek v daném sloupci vydělit součtem přes frekvence;

Seřadit relativní hodnoty výkonu do stejné struktury jako byly absolutní hodnoty

**end**

**Algoritmus 1:** Pseudokód přepočtu absolutních hodnot výkonu na relativní hodnoty

Po přepočtu na relativní hodnoty platilo, že součet relativních efektivních hodnot výkonu je pro každý časový okamžik přes všechny frekvence (0,5–30 Hz) roven jedné. Pro každý záznam a každou metodu odhadu spektra byly uloženy 2 matice obsahující absolutní a relativní efektivní hodnoty výkonu. Matice byly uloženy s rozměry (kanál x frekvence x čas).

Jedním z cílů bakalářské práce je porovnat dosažené výsledky s výsledky současných výzkumů. Autoři ve studii [2] uvedli, že změny výkonu při snění byly pozorovatelné v parieto-okcipitální oblasti. Z tohoto důvodu byly vybrány elektrody Pz, P3, P4, O1 a O2, které jsou v této oblasti umístěny. Pro tyto elektrody bylo vypočítáno, kolik procent výkonu se nachází v jednotlivých pásmech (alfa, beta, delta a theta). Celkový výkon byl vypočítán jako součet absolutních hodnot výkonů přes všechny frekvence (od 0,5 Hz do 30 Hz) a časy (analyzovaný úsek odpovídá zeleně vyznačené části na obrázku 5.2). Získané výsledky byly uspořádány do tabulek. Pro každou metodu odhadu spektra byly vytvořeny dvě tabulky (pro každou analyzovanou skupinu jedna). V jednotlivých sloupcích bylo zapsáno procentuální zastoupení výkonu v daném pásmu.

## 5.4 Statistické zhodnocení

Pro obě metody odhadu spektra bylo porovnáno, zda se statisticky významně liší skupiny probandů rozdělených na základě subjektivního paradigmatu spánků s přítomností snění (skupina ANO) a spánek bez přítomnosti snění (skupina NE). Dále bylo statisticky porovnáno procentuální zastoupení výkonu v jednotlivých pásmech pro elektrody z parieto-okcipitální oblasti.

Porovnání, zda se nachází statisticky významný rozdíl mezi skupinami, bylo provedeno pomocí metody Monte Carlo. Tato metoda provádí neparametrický statistický test. Pro každý vzorek v každém náhodném seskupení byl proveden nepárový t-test. Výstupem Monte Carlo metody jsou Monte Carlo odhady pravděpodobnosti významnosti a kritické hodnoty z permutačního rozdělení. [26]

Byly stanoveny následující hypotézy:


$H_0$ : Mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění se nenachází statisticky významný rozdíl

$H_1$ : Mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění se nachází statisticky významný rozdíl

Hypotézy byly testovány na hladině významnosti  $\alpha = 0,05$ . Testování nulové hypotézy bylo provedeno oboustranně. Monte Carlo metoda byla vypočítána s počtem randomizací 1000. Z důvodu provádění vícenásobného srovnávání byla využita korekce Bonferroni. Tato korekce zohledňuje počet provedených testů. Při

využití této korekce je nulová hypotéza na hladině významnosti  $\alpha$  zamítnuta, pokud je  $p$  hodnota menší než  $\alpha$  /počet provedených testů. [26]

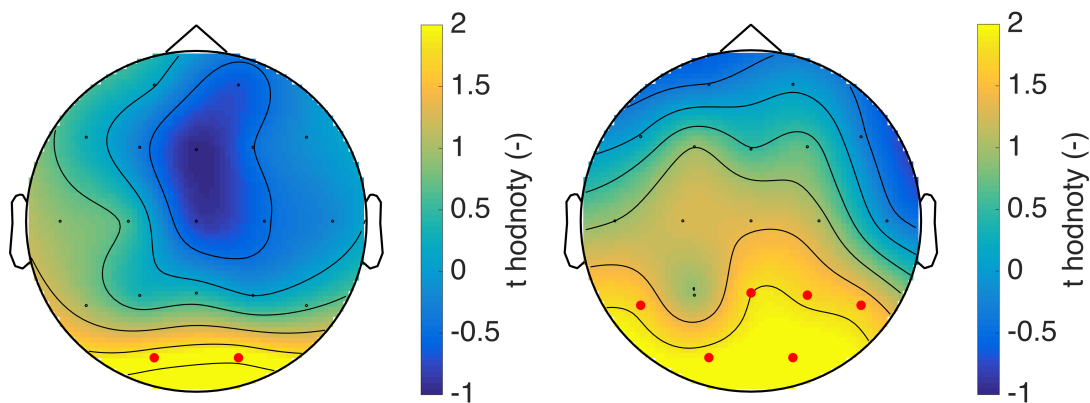
Pro každé pásmo (alfa, beta, delta, theta) byl proveden samostatný statistický test u obou metod odhadů spektra. Rozdíly mezi skupinami byly zobrazeny topografickým mapováním. Pomocí barevné stupnice jsou na topografických mapách zobrazeny  $t$  hodnoty. Kladné  $t$  hodnoty značí vyšší výkon pro skupinu subjektů, které měly ve spánku přítomný sen (skupina ANO). Záporné  $t$  hodnoty naopak značí oblasti, kde se nachází vyšší výkon pro skupinu probandů bez přítomnosti snění (skupina NE). Pro vizualizaci výsledků pomocí topografické mapy musely být přejmenovány některé elektrody podle názvů, které využívá knihovna Fieldtrip. Názvy a umístění elektrod po přejmenování zobrazuje následující obrázek 5.4. Vyhodnoceno bylo tedy celkem 19 kanálů.



Obrázek 5.4: Umístění a názvy elektrod dle knihovny Fieldtrip

Pro každý časový okamžik byla ve všech pásmech zobrazena samostatná topografická mapa. U každé metody odhadu spektra bylo zobrazeno celkem 320 topografických map (pro každé pásmo 80). Na jednotlivých mapách byly pomocí červené tečky označeny signifikantní elektrody ( $p \leq 0,05$ ). Obrázek 5.5 ukazuje zobrazení topografických map pro dva časové okamžiky z beta pásma.

Počty, kolikrát byly jednotlivé elektrody signifikantní (celkem z 80 časových okamžiků), byly pro všechna pásma zaznamenány do tabulky. Pro každé pásmo byla také u každé elektrody zobrazena závislost  $t$  hodnot na čase. Získané výsledky byly v jednotlivých pásmech slovně popsány. Pro každé pásmo byly vyhodnoceny oblasti, kde docházelo k největším rozdílům mezi skupinami ANO a NE.



Obrázek 5.5: Ukázka topografických map zobrazených pro každý časový okamžik s vyznačenými signifikantními elektrodami (rozdíl ANO - NE)

Pro ověření, zda existuje závislost mezi jednotlivými pásmy, byly zobrazeny časové průběhy  $t$  hodnot pro delta a beta pásmo do jednoho grafu. Cílem tohoto zobrazení bylo zjistit, zda pokles aktivity v jednom pásmu souvisí se zvýšením aktivity v druhém pásmu, či naopak. Toto zobrazení bylo provedeno na základě výsledků uvedených ve studii [2].

V další části této práce byly porovnány výsledky získané z různých metod odhadu spektra. Aby byly lépe porovnatelné výsledky získané pomocí krátkodobé Fourierovy transformace a pomocí vlnkové transformace, byly zobrazeny dvě topografické mapy pro každé pásmo a seřazeny vedle sebe. První mapa odpovídala výsledkům statistického testu provedeného z dat analyzovaných pomocí krátkodobé Fourierovy transformace, druhá mapa odpovídala výsledkům statistického testu provedeného z dat analyzovaných vlnkovou transformací. Pro lepší porovnatelnost byl u každé dvojice map nastaven stejný rozsah  $t$  hodnot. Tyto mapy byly zobrazeny pro celkem 20 sekund dlouhý časový interval, který odpovídá poslední čtvrtině zelené části na obrázku 5.2. Pro stejně dlouhý interval byly zobrazeny  $t$  hodnoty na modelu mozku ve studii [2]. V této podkapitole byly také porovnány počty statisticky významných rozdílů na jednotlivých elektrodách.

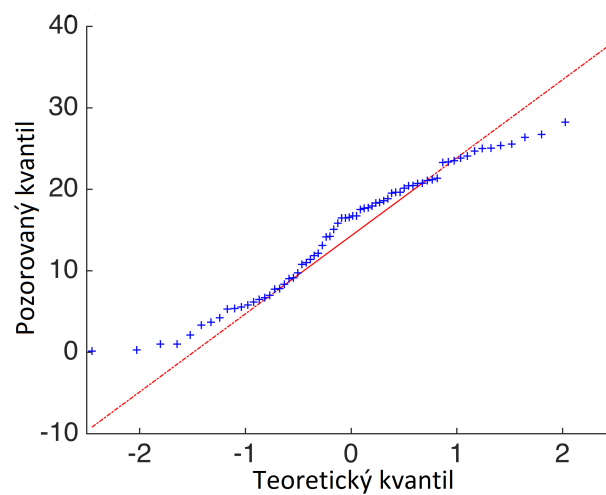
Pro lepší porovnatelnost metod odhadu spektra bez vlivu neparametrického testu bylo pro každé pásmo, každou skupinu a obě metody odhadu spektra vypočítáno průměrné spektrum. Průměr byl vypočítán z relativních efektivních hodnot výkonů přes všechny subjekty. Tato průměrná spektra byla následně od sebe odečtena v pořadí: průměrné spektrum získané z dat analyzovaných pomocí krátkodobé Fourierovy transformace mínus průměrné spektrum získané z dat analyzovaných vlnkovou transformací. Kladný rozdíl značil, že v daném pásmu a dané oblasti mozku bylo dosaženo vyšších výkonů pomocí krátkodobé Fourierovy transformace. Záporný rozdíl značil vyšší výkony při analýze vlnkovou transformací.

Porovnání zastoupení výkonů mezi skupinami v jednotlivých pásmech pro elektrody z parieto-okcipitální oblasti bylo provedeno pomocí neparametrického testu Mann-Whitney. Tento statistický test je ekvivalentní Wilcoxonovu testu. Neparametrický test byl zvolen z důvodu nenormálního rozdělení dat. Normalita rozdělení byla ověřena pomocí histogramu (obrázek 5.7) a Q-Q grafu (obrázek 5.6).

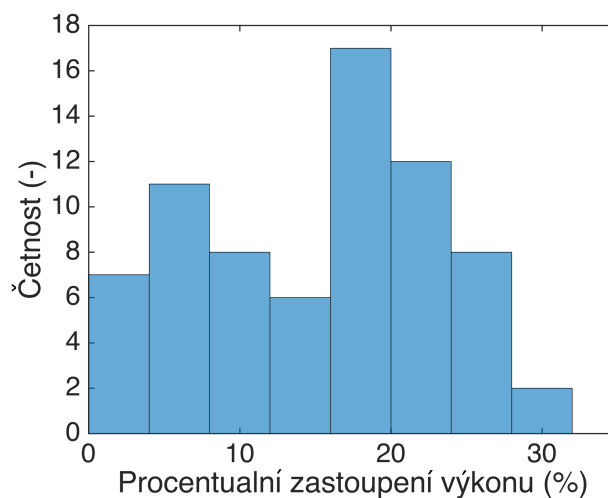
Byla testována hypotéza:

$H_0$ : Mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění se nenachází statisticky významný rozdíl v zastoupení výkonu v jednotlivých pásmech

$H_1$ : Mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění se nachází statisticky významný rozdíl v zastoupení výkonu v jednotlivých pásmech



Obrázek 5.6: Grafické ověření normality pomocí Q-Q grafu



Obrázek 5.7: Grafické ověření normality pomocí histogramu

## 6 Výsledky

Data byla analyzována nejprve pomocí krátkodobé Fourierovy transformace a následně pomocí vlnkové transformace. Pro obě metody odhadu spektra byly statisticky porovnány spektrální výkony na základě paradigmatu spánek s přítomností snění a spánek bez přítomnosti snění pro každé pásmo. Čtvrtá část této kapitoly se zabývá porovnáním výsledků získaných z analýzy pomocí krátkodobé Fourierovy transformace a pomocí vlnkové transformace. V poslední podkapitole jsou uvedeny výsledky pro elektrody z parieto-okcipitální oblasti.

### 6.1 Krátkodobá Fourierova transformace

Následující tabulka 6.1 zobrazuje, kolikrát byl statisticky významný rozdíl ( $p \leq 0,05$ ) mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění pro data analyzovaná pomocí krátkodobé Fourierovy transformace.

Tabulka 6.1: Počty statisticky významných rozdílů pro každou elektrodu, data analyzována pomocí krátkodobé Fourierovy transformace


Elektroda	Počet signifikantních elektrod (-)			
	Alfa pásmo	Beta pásmo	Delta pásmo	Theta pásmo
Fp1	4	3	4	7
Fp2	9	3	3	6
F3	8	5	6	6
F4	5	7	6	4
C3	14	10	5	6
C4	6	18	6	8
P3	13	7	7	6
P4	6	10	8	15
O1	6	10	4	14
O2	5	21	7	9
F7	7	3	6	8
F8	6	3	4	4
T7	11	8	3	3
T8	10	9	5	6
P7	13	5	2	5
P8	10	21	13	11
Fz	9	6	6	5
Cz	7	9	10	7
Pz	6	9	6	7

Statisticky významný rozdíl ( $p \leq 0,05$ ) byl vyhodnocen pro každou elektrodu a každý časový okamžik v jednotlivých pásmech. Bylo vyhodnoceno celkem 80 s záznamu s krokem dlouhým 1 s.



### 6.1.1 Alfa pásmo


V alfa pásmu (8,0–13,0 Hz) byly všechny elektrody alespoň jednou signifikantní. Získané výsledky zvýrazňují zejména parieto-temporální oblast, kde bylo přítomno nejvíce statisticky významných rozdílů mezi skupinami ANO a NE. V této oblasti dosahovala skupina NE bez přítomnosti snění vyšších výkonů. V parieto-temporální oblasti bylo více statisticky významných rozdílů mezi skupinami pozorovatelných v levé části mozku oproti pravé části mozku. V levé části mozku se jednalo zejména o oblast kolem elektrod T7, P7 a P3, která sahala až k elektrodě C3. Elektroda C3 byla v alfa pásmu celkem 14krát signifikantní a to nejvíce ze všech elektrod. V pravé části mozku bylo nejvíce statisticky významných rozdílů pozorovatelných v parieto-temporální oblasti, tedy v oblasti pod elektrodami T8 a P8. Následující obrázek 6.1 zobrazuje závislost t hodnot na čase pro každou elektrodu.



Obrázek 6.1: Závislost t hodnot na čase pro alfa pásmo (rozdíl ANO - NE), data analyzovaná pomocí krátkodobé Fourierovy transformace

Skupina ANO dosahovala v alfa pásmu vyšších výkonů pouze v okcipitální oblasti. V některých časových okamžicích tato skupina dosahovala také vyšších výkonů v pre-frontální oblasti, zejména na levé straně. Tyto rozdíly však ve většině časových okamžicích nebyly statisticky významné. Skupina NE oproti tomu dosahovala vyšších výkonů ve zbylých oblastech mozku. Obrázek 6.2 zobrazuje topografické


mapy reprezentující t hodnoty pro dva časové okamžiky. Jsou zde ukázány oblasti, ve kterých byly pozorovatelné největší rozdíly mezi skupinami.



Obrázek 6.2: Ukázka topografických map pro alfa pásmo (rozdíl ANO - NE)

### 6.1.2 Beta pásmo

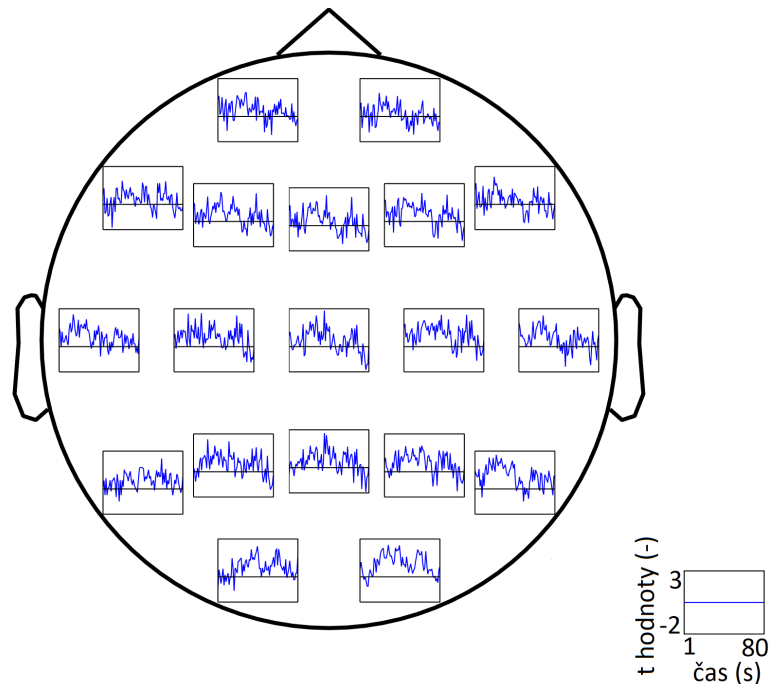
V beta pásmu (14,0–30,0 Hz) se nacházelo nejvíce statisticky významných rozdílů mezi skupinami ANO a NE. Nejvíce pozorovatelné rozdíly byly v parieto-okcipitální oblasti na pravé straně hlavy. V této oblasti dosahovala skupina ANO výrazně vyšších výkonů. Tato oblast zvýšeného vysokofrekvenčního výkonu pro skupinu s přítomností snění v některých případech sahala až do centrální oblasti, zejména do pravé části kolem elektrody C4. Nejvíce signifikantní elektrody byly elektrody s označením P8 a O2, kde byl statisticky významný rozdíl zaznamenán celkem 21krát. Obrázek 6.3 zobrazuje oblasti, kde byly přítomny největší rozdíly mezi skupinami.



Obrázek 6.3: Ukázka topografických map pro beta pásmo (rozdíl ANO - NE)

V některých časových okamžicích dosahovala skupina NE bez přítomnosti snění vyšších výkonů ve frontální a pre-frontální oblasti, nejvíce na pravé straně hlavy.

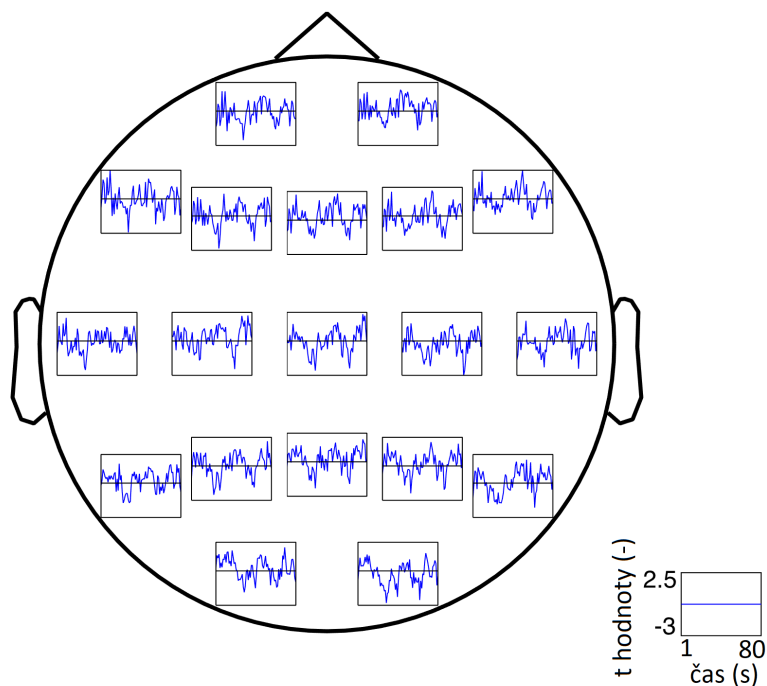
Tyto rozdíly však nebyly statisticky významné. V beta pásmu dosahovala skupina ANO ve většině časových okamžicích vyšších výkonů, a to zejména v zadních oblastech mozku. Na obrázku 6.3 je zobrazena časová závislost  $t$  hodnot pro každou elektrodu v beta pásmu.




Obrázek 6.4: Závislost  $t$  hodnot na čase pro beta pásmo (rozdíl ANO - NE), data analyzovaná pomocí krátkodobé Fourierovy transformace

### 6.1.3 Delta pásmo

V delta pásmu (0,5–4,0 Hz) bylo přítomno nejméně statisticky významných rozdílů mezi skupinami ANO a NE ze všech základních EEG pásem. V tomto pásmu byla nejvíce signifikantní elektroda P8 a to celkem 13krát. Pro tuto elektrodu dosahovala statisticky významně skupina ANO vyšších výkonů celkem 6krát a skupina NE dosahovala vyšších výkonů celkem 7krát. V tomto pásmu byla identifikována pouze okcipitální oblast, která pro skupinu NE dosahovala ve většině časových okamžicích vyšších výkonů. Následující obrázek 6.5 zobrazuje závislost  $t$  hodnot na čase pro jednotlivé elektrody v delta pásmu. Obrázek 6.6 ukazuje oblasti, kde byly přítomny největší rozdíly mezi skupinami pro dva časové okamžiky.



Obrázek 6.5: Závislost t hodnot na čase pro delta pásmo (rozdíl ANO - NE), data analyzovaná pomocí krátkodobé Fourierovy transformace

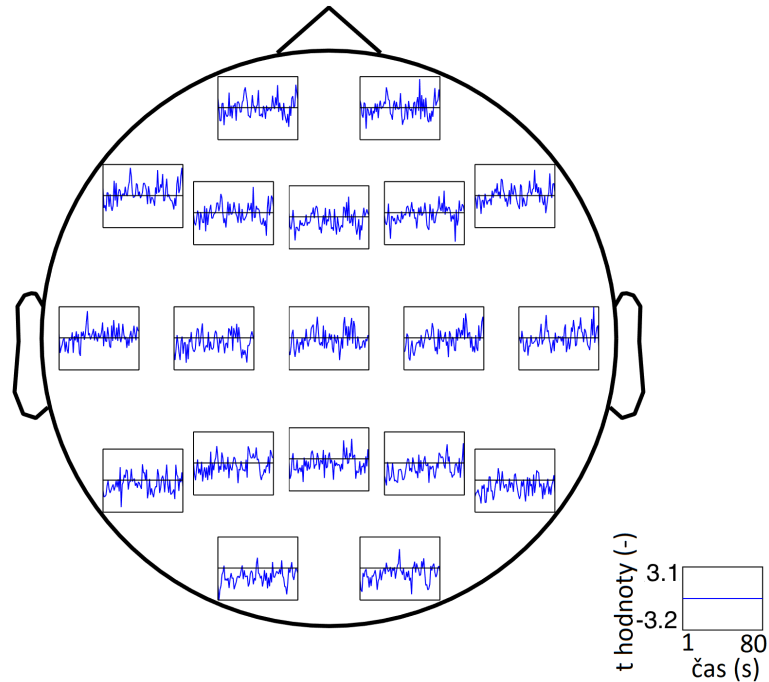


Obrázek 6.6: Ukázka topografických map pro delta pásmo (rozdíl ANO - NE)


#### 6.1.4 Theta pásmo

V theta pásmu (4,0–7,5 Hz) bylo nejvíce statisticky významných rozdílů pozorovatelných v okcipitální a pravé parietální oblasti mozku. Tato oblast se nacházela zejména pod elektrodami s označením P4, P8, O1 a O2. Nejvíce signifikantní elektrodou v theta pásmu byla elektroda P4, kde byl statisticky významný rozdíl pozoro-

rovatelný celkem 15krát. V okcipitální a parietální oblasti dosahovala skupina NE bez přítomnosti snění výrazně vyšších výkonů oproti skupině ANO s přítomností snění. Obrázek 6.7 zobrazuje závislost t hodnot na čase pro každou elektrodu.



Obrázek 6.7: Závislost t hodnot na čase pro theta pásmo (rozdíl ANO - NE), data analyzovaná pomocí krátkodobé Fourierovy transformace



Obrázek 6.8: Ukázka topografických map pro theta pásmo (rozdíl ANO - NE)

Naopak skupina ANO dosahovala vyšších výkonů v levé frontální až temporální oblasti. Rozdíly mezi skupinami ve frontální oblasti ovšem nebyly tak výrazné jako

rozdíly nacházející se v okcipitální a pravé parietální oblasti mozku. Obrázek 6.8 prezentuje topografické mapy pro dva časové okamžiky. Tyto mapy zobrazují oblasti, ve kterých byly přítomny největší rozdíly mezi skupinami ANO a NE.

## 6.2 Vlnková transformace

Následující tabulka 6.2 zobrazuje počet statisticky významných rozdílů ( $p \leq 0,05$ ) pro každou elektrodu ve 4 základních EEG pásmech. Přítomnost signifikantního rozdílu mezi skupinami ANO a NE byla vyhodnocena pro každou elektrodu a každý časový okamžik. Bylo vyhodnoceno celkem 80 časových okamžiků. Počty statisticky významných rozdílů mezi skupinami pro obě metody odhadu spektra jsou graficky zobrazeny na povrchu hlavy v kapitole 6.4.


Tabulka 6.2: Počty statisticky významných rozdílů pro každou elektrodu, data analyzována pomocí vlnkové transformace

Elektroda	Počet signifikantních elektrod (-)			
	Alfa pásmo	Beta pásmo	Delta pásmo	Theta pásmo
Fp1	7	6	2	6
Fp2	7	4	5	3
F3	10	5	5	4
F4	9	5	5	5
C3	11	8	6	13
C4	6	12	7	8
P3	10	6	4	4
P4	9	8	6	7
O1	6	8	2	5
O2	7	15	5	9
F7	5	4	2	5
F8	8	8	6	3
T7	9	9	4	3
T8	10	3	1	7
P7	16	3	3	3
P8	11	15	7	7
Fz	13	3	7	5
Cz	7	7	8	3
Pz	8	4	7	4

Tabulka zobrazuje, kolikrát byly jednotlivé elektrody signifikantní. Statisticky významný rozdíl ( $p \leq 0,05$ ) pro každou elektrodu byl vyhodnocen pro každý časový okamžik. Bylo vyhodnoceno celkem 80 s záznamu s krokem dlouhým 1 s.


### 6.2.1 Alfa pásmo

V alfa pásmu (8,0–13,0 Hz) bylo nejvíce statisticky významných rozdílů mezi skupinami ANO a NE pozorovatelných v parietální oblasti. V této oblasti dosahovala skupina NE bez přítomnosti snění výrazně vyšších výkonů oproti skupině ANO s přítomností snění. Jednalo se zejména o levou část mozku kolem elektrody P7. Vyšších výkonů dosahovala skupina NE také ve frontální oblasti kolem elektrody Fz. Skupina ANO dosahovala vyšších výkonů pouze v některých časových okamžicích, nejvíce v okcipitální oblasti. V alfa pásmu bylo v porovnání s ostatními pásmy přítomno nejvíce signifikantních rozdílů mezi skupinami. Následující obrázek 6.9 zobrazuje závislost t hodnot na čase pro každou elektrodu.



Obrázek 6.9: Závislost t hodnot na čase pro alfa pásmo (rozdíl ANO - NE), data analyzovaná pomocí vlnkové transformace


Některé časové okamžiky se vyznačovaly sníženým výkonem pro skupinu ANO oproti skupině NE i v pre-frontální oblasti. Tyto změny byly pozorovatelné více na pravé straně mozku oproti levé straně. Obrázek 6.10 zobrazuje oblasti, kde byly pozorovatelné signifikantní rozdíly mezi skupinami.



Obrázek 6.10: Ukázka topografických map pro alfa pásmo (rozdíl ANO - NE)


### 6.2.2 Beta pásmo

V beta pásmu (14,0–30,0 Hz) dosahovala největších rozdílů mezi skupinami pravá parieto-okcipitální oblast, která v některých okamžicích sahala až do centrální oblasti směrem k elektrodě C4. Tato oblast se vyznačovala zvýšenou aktivitou pro skupinu ANO s přítomností snění. Nejvíce signifikantních rozdílů mezi skupinami se nacházelo na elektrodách P8 a O2. Pouze v časových okamžicích na začátku analyzované části záznamu dosahovala v této oblasti skupina NE mírně vyšších výkonů. Skupina NE dosahovala v beta pásmu v některých časových okamžicích vyšších výkonů také ve frontální oblasti mozku. Tyto rozdíly však nebyly ve většině případech statisticky významné. Obrázek 6.12 zobrazuje pro každou elektrodu závislost t hodnot na čase. Následující obrázek 6.11 ukazuje části mozku, kde bylo přítomno nejvíce signifikantních rozdílů mezi skupinami. Každá topografická mapa odpovídá jednomu časovému okamžiku.



Obrázek 6.11: Ukázka topografických map pro beta pásmo (rozdíl ANO - NE)






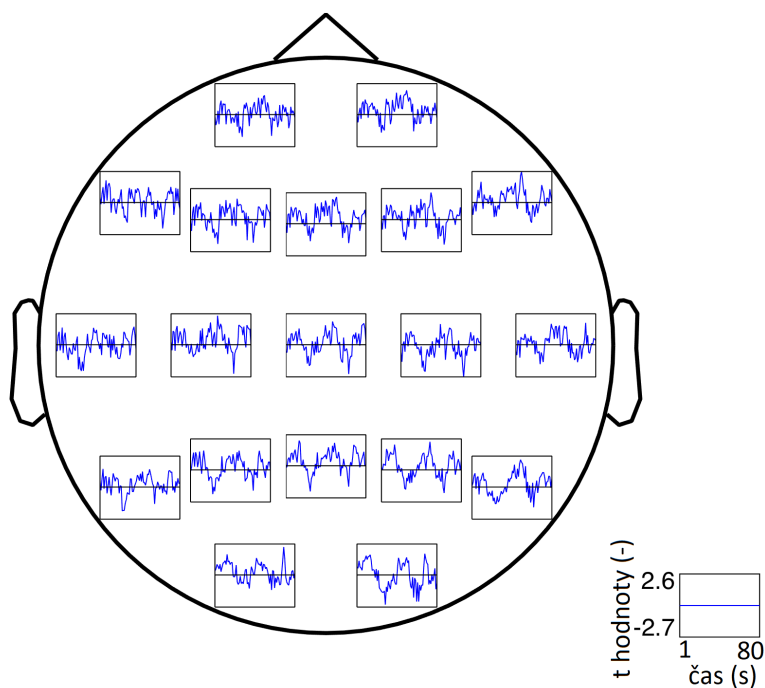
Obrázek 6.12: Závislost t hodnot na čase pro beta pásmo (rozdíl ANO - NE), data analyzovaná pomocí vlnkové transformace

### 6.2.3 Delta pásmo

V delta pásmu (0,5–4,0 Hz) se nejvíce statisticky významných rozdílů mezi skupinami nacházelo v pravé parietální oblasti zasahující až do centrální oblasti směrem k elektrodám Cz a C4. Oproti ostatním EEG pásmům se však v delta pásmu nacházelo nejméně signifikantních rozdílů mezi skupinami. V tomto pásmu nebyl na žádné elektrodě pozorovatelný výrazně vyšší nebo nižší výkon pro určitou skupinu po většinu analyzované části záznamu. Nejvíce statisticky významných rozdílů mezi skupinami se nacházelo na elektrodě Cz a to pouze 8. Z toho celkem v 6 případech dosahovala na této elektrodě skupina ANO vyššího výkonu, ve 2 případech dosahovala na elektrodě Cz skupina NE vyšších výkonů. Na obrázku 6.14 je zobrazena závislost t hodnot na čase pro každou elektrodu v delta pásmu. Obrázek 6.13 zobrazuje oblasti, kde bylo přítomno nejvíce statisticky významných rozdílů mezi skupinami. Je zde pozorovatelná pravá parietální oblast, ve které dosahovala skupina ANO v některých časových okamžicích vyšších výkonů (vlevo). Ve zbylých časech dosahovala v této oblasti skupina NE výrazně vyšších výkonů (vpravo).



Obrázek 6.13: Ukázka topografických map pro delta pásmo (rozdíl ANO - NE)

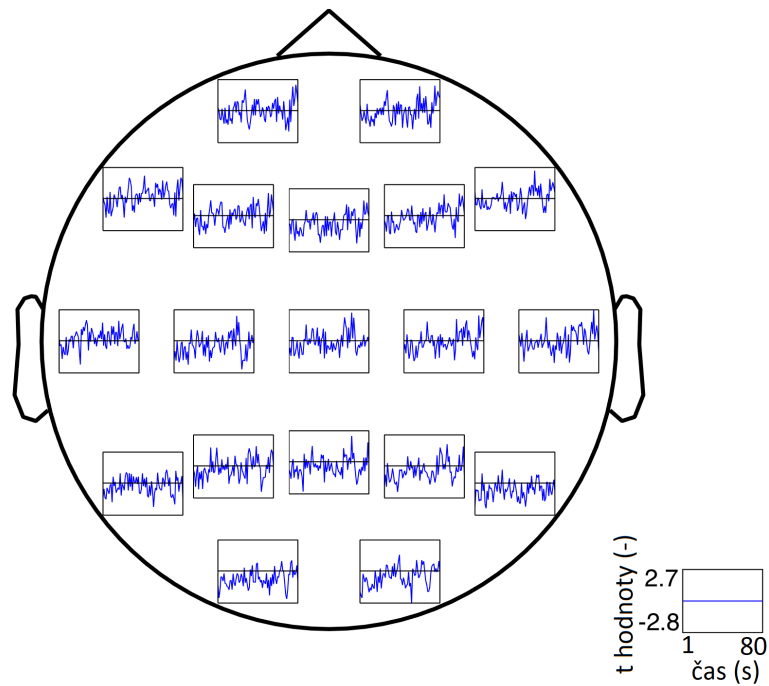


Obrázek 6.14: Závislost t hodnot na čase pro delta pásmo (rozdíl ANO - NE), data analyzovaná pomocí vlnkové transformace


### 6.2.4 Theta pásmo

V theta pásmu (4,0–7,5 Hz) se nejvíce statisticky významných rozdílů mezi skupinami ANO a NE nacházelo v levé centrální oblasti. V této části mozku dosahovala skupina NE vyššího výkonu. V theta pásmu bylo také pozorovatelné snížení výkonu v zadních oblastech mozku pro skupinu ANO s přítomností snění oproti skupině

NE bez přítomnosti snění. Tyto změny byly viditelné zejména v okcipitální a pravé parietální oblasti, kde téměř po celou analyzovanou dobu dosahovala skupina NE vyššího výkonu. Obrázek 6.15 zobrazuje pro každou elektrodu závislost t hodnot na čase v delta pásmu pro data analyzovaná pomocí vlnkové transformace. Na obrázku 6.16 jsou zobrazeny oblasti největších signifikantních rozdílů mezi skupinami.




Obrázek 6.15: Závislost t hodnot na čase pro theta pásmo (rozdíl ANO - NE), data analyzovaná pomocí vlnkové transformace



Obrázek 6.16: Ukázka topografických map pro theta pásmo (rozdíl ANO - NE)

### 6.3 Přelévání výkonu mezi pásmy

Závislost  $t$  hodnot na čase byla zobrazena pro nízkofrekvenční a vysokofrekvenční pásmo v jednom grafu u každé elektrody. Cílem tohoto zobrazení bylo ověřit, zda existuje nějaká závislost mezi jednotlivými pásmy. Ze získaných výsledků je pozorovatelná závislost mezi delta a beta pásmem, kterou zobrazují následující obrázky 6.17 a 6.18. Obrázek 6.17 odpovídá datům analyzovaným pomocí krátkodobé Fourierovy transformace. Stejný trend byl pozorovatelný i u dat analyzovaných pomocí vlnkové transformace. Toto zobrazení bylo provedeno na základě výsledků získaných ve studii [2].

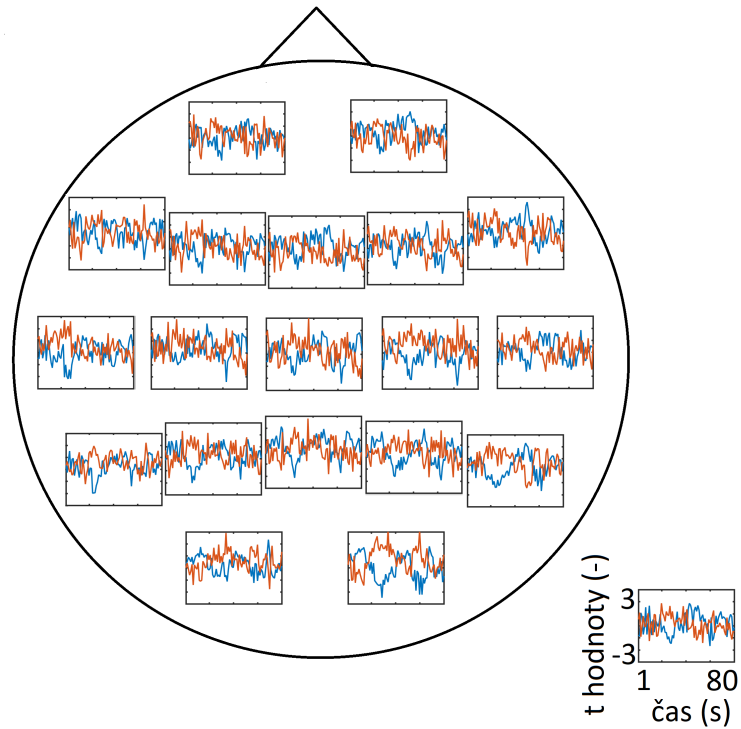


Obrázek 6.17: Závislost  $t$  hodnot na čase pro data analyzovaná pomocí krátkodobé Fourierovy transformace (rozdíl ANO - NE), červená barva pro beta pásmo (14,0–30,0 Hz), modrá barva pro delta pásmo (0,5–4,0 Hz)

Závislost mezi delta a beta pásmem byla nejvíce pozorovatelná v zadních oblastech mozku. Na zobrazených obrázcích je viditelný zvýšený vysokofrekvenční výkon pro skupinu ANO s přítomností snění. Současně tato skupina dosahovala sníženého nízkofrekvenčního výkonu oproti skupině NE. Tyto změny jsou nejvíce viditelné v parieto-okcipitální oblasti na pravé straně mozku. V této oblasti bylo přítomno nejvíce statisticky významných rozdílů mezi skupinami v beta pásmu pro obě me-

tody odhadu spektra. Snění tedy bylo spojeno se zvýšením aktivity v beta pásmu a současným snížením aktivity v pásmu delta.

Následující obrázek 6.18 zobrazuje závislost  $t$  hodnot na čase v pásmu delta a beta pro data analyzovaná pomocí vlnkové transformace. Získaný trend výsledků je stejný u obou metod odhadu spektra.




Obrázek 6.18: Závislost  $t$  hodnot na čase pro data analyzovaná pomocí vlnkové transformace (rozdíl ANO - NE), červená barva pro beta pásmo (14,0–30,0 Hz), modrá barva pro delta pásmo (0,5–4,0 Hz)

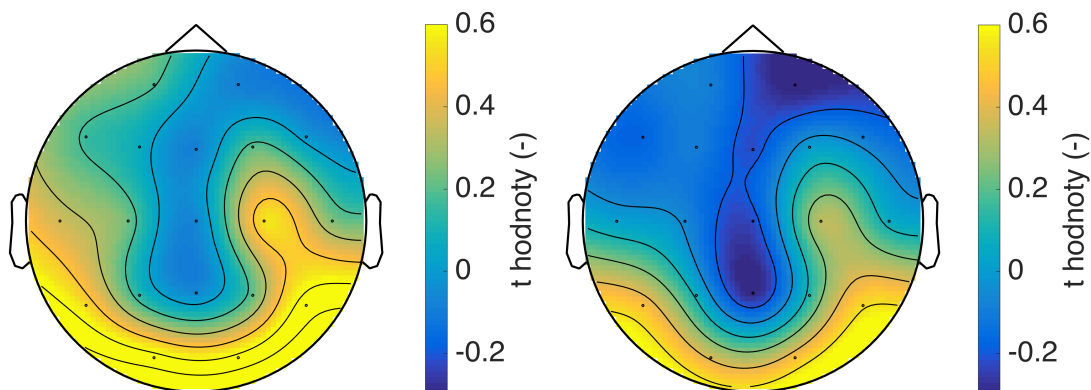
## 6.4 Porovnání vlivu odhadu výkonového spektra

Další část této kapitoly se zabývá porovnáním výsledků získaných z časově frekvenční analýzy provedené pomocí krátkodobé Fourierovy transformace a pomocí vlnkové transformace. Pro každé pásmo a každou metodu odhadu spektra je zobrazena topografická mapa reprezentující  $t$  hodnoty. Tyto topografické mapy byly zobrazeny pro celkem 20 sekund dlouhý časový interval, který byl brán od konce analyzované části.


Pro lepší porovnatelnost byl u každého pásma nastaven stejný rozsah  $t$  hodnot. Ze získaných výsledků je patrné, že pro obě metody odhadu spektra byl získaný stejný trend. Následující obrázky 6.19, 6.20, 6.21 a 6.22 zobrazují topografické mapy pro příslušná pásma.




Obrázek 6.19: Topografické mapy zobrazující  $t$  hodnoty pro alfa pásmo (rozdíl ANO - NE), data analyzována pomocí krátkodobé Fourierovy transformace (vlevo) a vlnkové transformace (vpravo)



Obrázek 6.20: Topografické mapy zobrazující  $t$  hodnoty pro beta pásmo (rozdíl ANO - NE), data analyzována pomocí krátkodobé Fourierovy transformace (vlevo) a vlnkové transformace (vpravo)

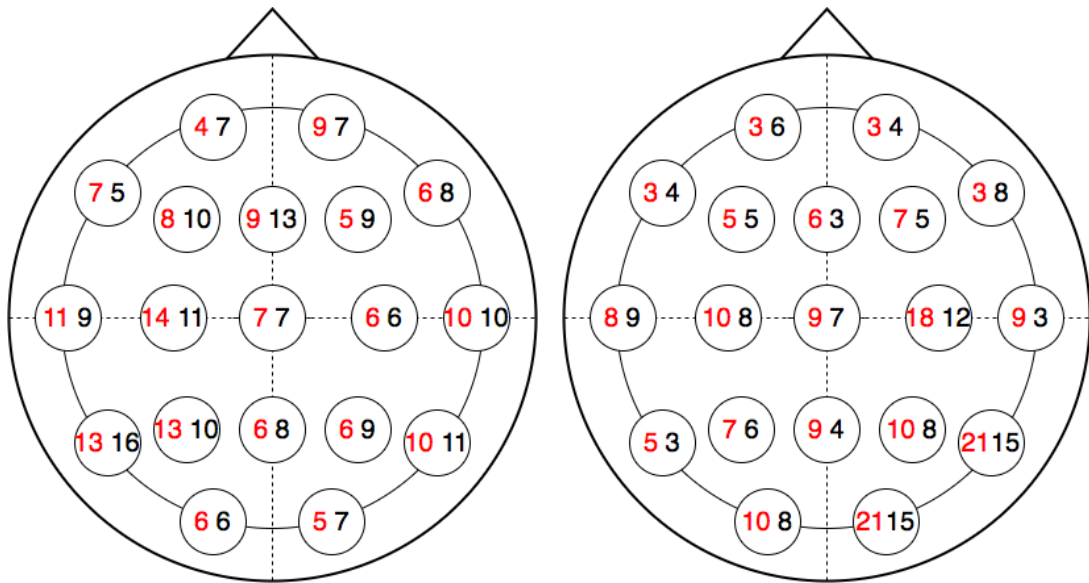


Obrázek 6.21: Topografické mapy zobrazující t hodnoty pro delta pásmo (rozdíl ANO - NE), data analyzována pomocí krátkodobé Fourierovy transformace (vlevo) a vlnkové transformace (vpravo)

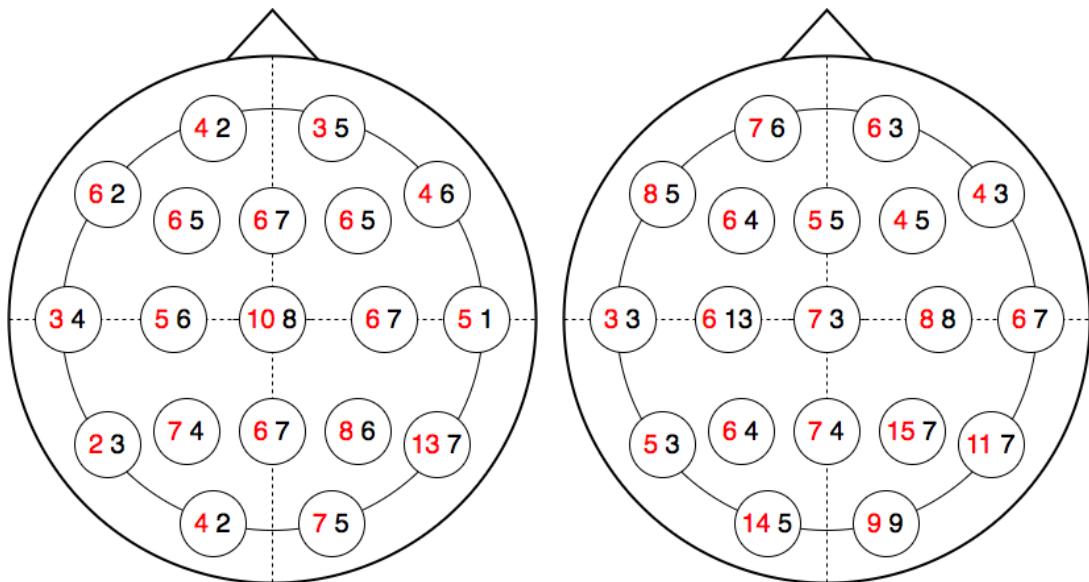


Obrázek 6.22: Topografické mapy zobrazující t hodnoty pro theta pásmo (rozdíl ANO - NE), data analyzována pomocí krátkodobé Fourierovy transformace (vlevo) a vlnkové transformace (vpravo)

Pro každé pásmo byly následně porovnány počty signifikantních rozdílů mezi skupinami získané z analýzy pomocí krátkodobé Fourierovy transformace a vlnkové transformace. U obou metod odhadu spektra bylo nejméně statisticky významných rozdílů přítomno v delta pásmu. Naopak nejvíce signifikantních rozdílů bylo přítomno v beta pásmu u analýzy krátkodobou Fourierovou transformací. Při odhadu spektra pomocí vlnkové transformace bylo přítomno nejvíce statisticky významných rozdílů v alfa pásmu. Následující obrázky 6.23 a 6.24 zobrazují počty signifikantních rozdílů pro různé elektrody. Na pozici každé elektrody je zapsán počet statisticky významných rozdílů pro data analyzovaná krátkodobou Fourierovou transformací červenou barvou vlevo. Černě vpravo je zapsaný počet statisticky významných rozdílů mezi skupinami pro odhad spektra vlnkovou transformací.




Obrázek 6.23: Počty kolikrát byly jednotlivé elektrody signifikantní, červeně pro data analyzovaná pomocí krátkodobé Fourierovy transformace, černě pro data analyzovaná pomocí vlnkové transformace, alfa pásmo (vlevo), beta pásmo (vpravo)




Obrázek 6.24: Počty kolikrát byly jednotlivé elektrody signifikantní, červeně pro data analyzovaná pomocí krátkodobé Fourierovy transformace, černě pro data analyzovaná pomocí vlnkové transformace, delta pásmo (vlevo), theta pásmo (vpravo)



Pro každou skupinu a každé EEG pásmo bylo vypočítáno průměrné spektrum pro obě metody odhadu spektra. Tato průměrná spektra byla následně od sebe odečtena. Zobrazeny byly topografické mapy reprezentující rozdíl relativních efektivních hodnot výkonu. Kladné hodnoty značí dosažení vyšších výkonů při analýze pomocí krátkodobé Fourierovy transformace. Záporné hodnoty značí vyšší výkony při využití vlnkové transformace. Zobrazené mapy odpovídají rozdílu z posledních dvaceti sekund analyzovaného záznamu. Cílem tohoto zobrazení bylo zjistit, v jakých pásmech a oblastech mozku byly přítomny největší rozdíly mezi metodami odhadu spektra. Obrázky 6.25, 6.26, 6.27 a 6.28 zobrazují topografické mapy rozdílu pro jednotlivá EEG pásma.




Obrázek 6.25: Rozdíl relativních efektivních hodnot výkonu pro alfa pásmo, skupina ANO (vlevo), skupina NE (vpravo)




Obrázek 6.26: Rozdíl relativních efektivních hodnot výkonu pro beta pásmo, skupina ANO (vlevo), skupina NE (vpravo)

Ze získaných výsledků je viditelné, že při analýze pomocí krátkodobé Fourierovy transformace bylo v pásmech alfa, beta a theta ve všech oblastech mozku dosaženo vyšších výkonů. Pouze v delta pásmu bylo dosaženo vyšších výkonů při analýze pomocí vlnkové transformace. Nejmenší rozdíly mezi průměrnými relativními efektivními hodnotami výkonu byly přítomny v beta pásmu. V tomto pásmu se nacházely

nejmenší rozdíly v okcipitálně-parietální oblasti na pravé straně a ve frontální oblasti mozku. Největší rozdíly byly naopak přítomny v pásmu delta.



Obrázek 6.27: Rozdíl relativních efektivních hodnot výkonu pro delta pásmo, skupina ANO (vlevo), skupina NE (vpravo)



Obrázek 6.28: Rozdíl relativních efektivních hodnot výkonu pro theta pásmo, skupina ANO (vlevo), skupina NE (vpravo)

## 6.5 Zastoupení výkonu v parieto-okcipitální oblasti

Pro parieto-okcipitální oblast mozku bylo vypočteno, kolik procent výkonu se nachází v jednotlivých pásmech. Jednalo se o část mozku, kde bylo přítomno nejvíce rozdílů mezi skupinami. Tato oblast byla vybrána také na základě současného výzkumu. V publikaci [2] bylo uvedeno, že snění bylo spojeno se změnami aktivity právě v této oblasti mozku. Výpočet byl proveden na elektrodách P3, P4, Pz, 01 a 02. Procentuální zastoupení výkonu v jednotlivých pásmech je pro obě skupiny a obě metody odhadu spektra uvedeno v přílohách této práce (příloha A).

Na základě provedení neparametrického Mann-Whitney testu byla pro každé pásmo otestována nulová hypotéza ( $H_0$ : Mezi skupinami spánek s přítomností snění

a spánek bez přítomnosti snění se nenachází statisticky významný rozdíl v zastoupení výkonu pro dané pásmo) na hladině významnosti 5 %. Následující tabulka zobrazuje získané p hodnoty z jednotlivých neparametrických testů.

Tabulka 6.3: p hodnoty pro jednotlivá pásma u obou metod odhadu spektra

	<b>Fourierova transformace p hodnoty (-)</b>	<b>Vlnková transformace p hodnoty (-)</b>
Alfa pásmo	0,1298	0,1213
Beta pásmo	0,0075	0,0120
Delta pásmo	0,0340	0,0703
Theta pásmo	0,1066	0,2079

Na hladině významnosti 5 % byla zamítnuta nulová hypotéza pro beta pásmo u obou metod odhadu spektra. Nulová hypotéza byla zamítnuta také v delta pásmu, ale pouze v případě analýzy pomocí krátkodobé Fourierovy transformace. Ze získaných výsledků tedy vyplývá, že mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění se nachází signifikantní rozdíl v zastoupení výkonu v beta pásmu, v delta pásmu byl statisticky významný rozdíl v zastoupení výkonu přítomen pouze v případě analýzy krátkodobou Fourierovou transformací.

## 7 Diskuse

V této kapitole jsou diskutovány jednotlivé části bakalářské práce: analýza pomocí krátkodobé Fourierovy transformace, analýza pomocí vlnkové transformace, přelévání výkonu mezi jednotlivými pásmy, porovnání metod odhadu spektra a zastoupení výkonu v parieto-okcipitální oblasti. Dále je zde uvedeno porovnání dosažených výsledků s výsledky nejnovějších studií. Konec této kapitoly se zabývá limitacemi práce. Pro lepší přehlednost je tato kapitola rozdělena na příslušné podkapitoly.

Cílem práce bylo provést frekvenční analýzu spánkových EEG záznamů pro dvě skupiny probandů. Zkoumané skupiny byly rozděleny na základě přítomnosti a nepřítomnosti snění v průběhu spánku. Vzhledem k charakteru práce byly zvoleny metody časově frekvenční analýzy, konkrétně krátkodobá Fourierova transformace a vlnková transformace využívající Morletovu vlnku. Zkoumaný subjekt během doby trvání analyzovaného záznamu mohl snít pouze v určité části, z tohoto důvodu musela být zachována časová informace.

### 7.1 Krátkodobá Fourierova transformace

Hlavním zjištěním této práce je, že snění je spojeno se zvýšením beta aktivity v zadních oblastech mozku. Jednalo se konkrétně o parieto-okcipitální oblast, kde byly nejvýraznější změny pozorovány na pravé straně hlavy. Zvýšení aktivity v beta pásmu bylo spojeno se snížením aktivity v pásmu delta. V nízkofrekvenčním rozsahu ovšem bylo přítomno nejméně signifikantních rozdílů. Pomocí této metody odhadu spektra byl na hladině významnosti 5 % zjištěn statisticky významný rozdíl v zastoupení výkonu pro pásma delta a beta v parieto-okcipitální oblasti.

### 7.2 Vlnková transformace

Při analýze pomocí vlnkové transformace bylo nejvíce statisticky významných rozdílů přítomných v alfa pásmu, zejména na levé straně mozku. Zde bylo snění spojeno s poklesem aktivity v parietální oblasti. Snížená aktivita pro skupinu s přítomností snění sahala i do temporální, centrální a frontální oblasti mozku. V těchto oblastech však bylo přítomno méně statisticky významných rozdílů. V beta pásmu bylo snění spojeno se zvýšením aktivity v parieto-okcipitální oblasti mozku. Zvýšení vysokofrekvenční aktivity bylo spojeno s poklesem nízkofrekvenční aktivity. Pomocí této metody odhadu spektra byl přítomen na hladině významnosti 5 % signifikantní rozdíl v zastoupení výkonu v parieto-okcipitální oblasti pro pásmo beta.

### 7.3 Přelévání výkonu mezi jednotlivými pásmy

Na obrázcích 6.17 a 6.18 je viditelné, že snížená aktivita v delta pásmu a současně zvýšená aktivita v beta pásmu nebyla přítomna ve všech časových okamžicích. Časové okamžiky, kdy bylo viditelné snížení aktivity v pásmu beta a současné zvýšení aktivity v pásmu delta odpovídalo nepřítomnosti snění. Tato situace je nejvíce viditelná v prvních patnácti sekundách analyzovaného záznamu. Zvýšení delta aktivity v parietální oblasti je také zobrazeno na ukázkách topografických na obrázcích 6.6 a 6.13. V průběhu doby trvání analyzovaného záznamu tedy snění nebylo přítomno po celou dobu.

### 7.4 Porovnání metod odhadu spektra

Pro obě metody odhadu spektra byly zobrazeny topografické mapy reprezentující t hodnoty pro každé pásmo. Porovnáním těchto map v jednotlivých pásmech je viditelné, že u obou metod odhadu spektra bylo dosaženo stejného trendu výsledků. Viditelné rozdíly mohly být způsobeny vybranou metodou odhadu spektra nebo využitím neparаметrického testu.

Pro lepší porovnatelnost výsledků získaných z různých metod odhadu spektra byl zobrazen rozdíl průměrných relativních efektivních hodnot výkonů. V předchozím zobrazení mohly být rozdíly způsobeny neparаметrickým testem nebo vybranou metodou odhadu spektra. V tomto případě byl odstraněn vliv statistického testu. Rozdíl byl proveden pro obě skupiny a každé pásmo. Ze získaných výsledků je viditelné, že při analýze pomocí krátkodobé Fourierovy transformace bylo dosaženo v pásmech alfa, beta a theta vyšších výkonů. V delta pásmu bylo dosaženo vyšších výkonů pomocí vlnkové transformace. V tomto pásmu byly přítomny největší rozdíly mezi skupinami. Naopak čím vyšší frekvenční rozsahy byly porovnávány, tím menší byly rozdíly mezi metodami.

Pro analýzu EEG se běžně používají obě uvedené metody odhadu spektra. Ve studii porovnávající tyto dvě metody odhadu spektra bylo uvedeno, že krátkodobá Fourierova transformace je vhodnější pro analýzu EEG v reálném čase vzhledem ke kratší době zpracování. Naopak vlnková transformace byla určena vhodnější pro klinické a výzkumné práce. V této studii byly uvedené metody porovnány na EEG záznamech u dětských pacientů s epilepsií. [27]

Ve studii porovnávající tyto dvě metody odhadu spektra na spánkových EEG záznamech bylo zjištěno, že výsledky získané pomocí krátkodobé Fourierovy transformace jsou výrazně ovlivněny vybranou šířkou okénka. Pomalé změny spojené s přechodem do spánku byly nejlépe pozorovatelné při šířce okénka 60 sekund. Rychlé změny byly naopak viditelnější, pokud se šířka okénka pohybovala v in-

tervalu 1–3 sekundy. Pomocí vlnkové transformace byly dobře pozorovatelné rychlé i pomalé změny. Zejména v nízkofrekvenčním rozsahu bylo pomocí této metody možno rozlišit různé úrovně hlubokého spánku. [28]

V této bakalářské práci se nejvíce statisticky významných rozdílů mezi skupinami nacházelo ve vysokofrekvenčním rozsahu. V tomto rozsahu frekvencí byly rozdíly mezi metodami nejmenší. Ve vysokých frekvencích byl tedy vliv odhadu spektra minimální. Naopak pro analýzu nízkofrekvenčního rozsahu byla vyhodnocena lepší metodou vlnková transformace. Tato metoda dosahovala v delta pásmu vyšších výkonů. Největší rozdíly v delta pásmu mezi metodami mohly být způsobeny šířkou okénka u analýzy pomocí krátkodobé Fourierovy transformace, které bylo nastaveno na délku 2 sekundy. Možným řešením by bylo zvětšení délky Hanningova okénka u krátkodobé Fourierovy transformace. Tím by ovšem došlo ke zhoršení výsledků ve vysokofrekvenčním rozsahu.

V porovnání s publikací [2] bylo dosaženo podobných výsledků využitím krátkodobé Fourierovy transformace. V této uvedené studii byla spektrální výkonová hustota vypočítána pomocí Welchovy modifikované metody periodogramu. Využitím odlišné metody mohly být v této publikaci stanoveny odlišné výsledky.

## 7.5 Porovnání výsledků se současnými výzkumy

V publikaci [2] bylo uvedeno, že snění je spojeno s poklesem nízkofrekvenční aktivity (1–4 Hz) v zadních kortikálních oblastech mozku. Pokles nízkofrekvenční aktivity byl spojen s nárustem vysokofrekvenční aktivity (20–50 Hz) ve stejných oblastech mozku. V této bakalářské práci se nejvíce rozdílů mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění nacházelo v zadních oblastech mozku, konkrétně v parieto-okcipitální oblasti. V této oblasti mozku dosahovala skupina s přítomností snění vyšších výkonů ve vysokofrekvenčním rozsahu. Čím více docházelo ke zvýšení aktivity v beta pásmu, tím větší bylo pozorovatelné snížení delta aktivity. Závislost mezi delta a beta pásmem je zobrazena v kapitole 6.3. Oproti uvedené studii [2] byl v této bakalářské práci analyzovaný užší frekvenční rozsah. Získaný trend odpovídá výsledkům studie [2]. V nízkofrekvenčním rozsahu však většina rozdílů mezi skupinami nebyla statisticky významná.

Ztráta vědomí je spojena s pomalými vlnami (1–4 Hz), které zabraňují vzniku stabilních interakcí mezi kortikálními oblastmi. Zvýšení nízkofrekvenční aktivity je tedy spojeno s absencí snění. Naopak vysoké frekvence mohou naznačovat oblasti mozku, které vykazují zvýšenou aktivitu. [2]

V další studii, která se zabývala elektrofyziologickými korelátů snění v NREM spánku bylo uvedeno, že snění je spojeno se snížením delta aktivity během posledního segmentu spánku v levé frontální a temporo-parietální oblasti mozku. V uvedené

studii [4] byl analyzovaný frekvenční rozsah 0,5–25,0 Hz. Tyto výsledky se neshodují s výsledky uvedenými v této bakalářské práci, kde nejvíce změn mezi skupinami bylo přítomno v parieto-okcipitální oblasti, zejména na pravé straně mozku. [4]

Autoři v publikaci [5] uvedli, že v druhé fázi NREM spánku bylo snění spojeno se snížením relativního výkonu pod 1 Hz doprovázené zvýšením výkonu nad 4 Hz. V této bakalářské práci byla provedena extrakce výkonového spektra pouze pro 4 základní EEG pásma (alfa, beta, delta, theta). Oproti uvedené publikaci v této bakalářské práci nebyly zvlášť porovnány spektrální výkony pro nízké frekvence do 1 Hz. Výsledky uvedené v publikaci [5] pro nízké frekvence do 1 Hz tedy nelze porovnat s dosaženými výsledky v této práci. V alfa, beta a theta pásmu autoři zmiňované publikace [5] zjistili, že snění je spojeno se zvýšením aktivity. Zvýšený výkon pro skupinu s přítomností snění byl pozorovatelný téměř po celé ploše mozku. V této bakalářské práci byly identifikovány pouze určité oblasti mozku, kde skupina s přítomností snění dosahovala vyšších výkonů. Jednalo se nejvíce o okcipitální oblast mozku, kde skupina s přítomností snění dosahovala v beta pásmu výrazně vyšších výkonů.

## 7.6 Limitace práce

Při statistickém zpracování byla z důvodu násobného srovnávání využita korekce Bonferroni. Tato korekce patří mezi nejpřísnější. Využitím korekční metody Bonferroni je obtížné dosáhnout zamítnutí nulové hypotézy. Vlivem permutací mohla v některých případech vyjít p hodnota těsně kolem 0,05. Zamítnutí nebo nezamítnutí nulové hypotézy tedy bylo závislé na tom, jak permutace v daném případě dopadly. Možným řešením by bylo využití méně přísné korekce. Jedná se např. o korekční metodu fdr.

Při porovnání metod odhadu výkonového spektra, tedy krátkodobé Fourierovy transformace a vlnkové transformace využívající Morletovu vlnku, bylo při zobrazení t hodnot dosaženo stejného trendu výsledků. V určitých oblastech mozku byl získán pomocí jedné z metod větší rozdíl mezi skupinami. Tyto odchylky mezi metodami odhadu spektra mohly být způsobeny využitím neparametrického testu. V obou případech byl získán stejný trend výsledků bez ohledu na využitou metodu odhadu spektra.

## 8 Závěr

Cílem práce bylo provést frekvenční analýzu pomocí dvou metod odhadu spektra pro spánkové záznamy s přítomností a nepřítomností snění. Získané výsledky měly přispět k popisu charakteru snění v EEG datech a zvýraznit oblasti mozku, kde bylo v rámci snění přítomno nejvíce změn.

Byla provedena časově frekvenční analýza pro dvě skupiny probandů pomocí krátkodobé Fourierovy transformace a pomocí vlnkové transformace. Skupiny probandů byly rozděleny na základě přítomnosti a nepřítomnosti snění v průběhu spánku. Analyzováno bylo celkem 126 spánkových EEG záznamů. Výkonová spektra byla mezi skupinami statisticky porovnána pomocí neparametrického permutačního testu pro obě metody odhadu spektra. Pro každé EEG pásmo a každou metodu odhadu spektra byly popsány oblasti, kde bylo přítomno nejvíce rozdílů mezi skupinami spánek s přítomností snění a spánek bez přítomnosti snění. V rámci snění byla vyhodnocena také závislost mezi jednotlivými pásmy. Na základě současných výzkumů byla vybrána parieto-okcipitální oblast, kde bylo statisticky porovnáno procentuální zastoupení výkonu v jednotlivých pásmech. Získané výsledky byly porovnány s výsledky nejnovějších studií. Bylo provedeno také porovnání využitých metod odhadu spektra.

Výpočtem časově frekvenční analýzy pomocí dvou metod odhadu spektra pro spánkové záznamy s přítomností a nepřítomností snění bylo zjištěno, že snění je spojeno se zvýšením beta aktivity v parieto-okcipitální oblasti mozku. Zvýšení vysokofrekvenční aktivity bylo spojeno s poklesem aktivity delta. V alfa pásmu dosahovala skupina s přítomností snění sníženého výkonu v parieto-temporální oblasti. Snížená aktivita v alfa pásmu sahala i do ostatních oblastí mozku, zejména do centrální a frontální oblasti. Výpočtem zastoupení výkonu v jednotlivých pásmech pro parieto-okcipitální oblast byl zjištěn statisticky významný rozdíl v pásmu beta. V delta pásmu byl signifikantní rozdíl v zastoupení výkonu dosažen pouze při analýze pomocí krátkodobé Fourierovy transformace, záleželo tedy na metodě odhadu spektra. Porovnáním metod odhadu spektra byla vyhodnocena vlnková transformace vhodnější metodou pro analýzu EEG. V této práci byl na robustním datasetu popsán charakter snění v EEG datech.



## Seznam použité literatury

1. LEVIN, Ross; NIELSEN, Tore A. Disturbed Dreaming, Posttraumatic Stress Disorder, and Affect Distress: A Review and Neurocognitive Model. *Psychological Bulletin*. 2007, roč. 133, č. 3, s. 482–528. Dostupné z DOI: [10.1037/0033-2909.133.3.482](https://doi.org/10.1037/0033-2909.133.3.482).
2. SICLARI, Francesca; BAIRD, Benjamin; PEROGAMVROS, Lampros; BERNARDI, Giulio; LAROCQUE, Joshua; RIEDNER, Brady; BOLY, Melanie; POSTLE, Bradley; TONONI, Giulio. The neural correlates of dreaming. *Nature Neuroscience*. 2017, roč. 20, č. 6, s. 872–878. Dostupné z DOI: [10.1038/nn.4545](https://doi.org/10.1038/nn.4545).
3. SICLARI, Francesca; BERNARDI, Giulio; CATALDI, Jacinthe; TONONI, Giulio. Dreaming in NREM sleep: A high-density EEG study of slow waves and spindles. *The Journal of Neuroscience*. 2018, roč. 38, č. 43, s. 9175–9185. Dostupné z DOI: [10.1523/JNEUROSCI.0855-18.2018](https://doi.org/10.1523/JNEUROSCI.0855-18.2018).
4. SCARPELLI, Serena; D'ATRI, Aurora; MANGIARURA, Anastasia; MANZARO, Cristina; GORGONIL, Maurizio; SCHIAPPA, Cinzia; FERRARA, Michele; GENNARO, Luigi De. Predicting Dream Recall: EEG Activation During NREM Sleep or Shared Mechanisms with Wakefulness? *Brain Topography*. 2017, roč. 30, č. 5, s. 629–638. Dostupné z DOI: [10.1007/s10548-017-0563-1](https://doi.org/10.1007/s10548-017-0563-1).
5. ZHANG, Jing; WAMSLEY, Erin J. EEG predictors of dreaming outside of REM sleep. *Psychophysiology*. 2019, roč. 56, č. 7. Dostupné z DOI: [10.1111/psyp.13368](https://doi.org/10.1111/psyp.13368).
6. KRAJČA, Vladimír; MOHYLOVÁ, Jitka. *Číslíkové zpracování neurofyzilogických signálů*. 1. vyd. Praha: České vysoké učení technické v Praze, 2011. ISBN 9788001047217.
7. SANEI, Saeid; CHAMBERS, Jonathon. *EEG signal processing*. 2007. vyd. Hoboken, NJ: John Wiley & Sons, 2007. ISBN 0470025816.
8. SUBHA, D. Puthankattil; JOSEPH, Paul K.; U, Rajendra Acharay; LIM, C. M. EEG Signal Analysis: A Survey. *Journal of Medical Systems*. 2010, roč. 34, č. 2, s. 195–212. Dostupné z DOI: [10.1007/s10916-008-9231-z](https://doi.org/10.1007/s10916-008-9231-z).
9. MALMIVUO, Jaakko; PLONSEY, Robert. *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. 1st ed. New York: Oxford University Press, 1995. ISBN 978-0195058239.
10. RIEGER, Josef; LHOTSKÁ, Lenka; KRAJČA, Vladimír. Zpracování dlouhodobých EEG záznamů. *Advances in Electrical and Electronic Engineering*. 2005, roč. 4, č. 3, s. 151–156.

11. WACKER, Marcus; WITTE, Heiko. Time-frequency Techniques in Biomedical Signal Analysis. *Methods of Information in Medicine*. 2013, roč. 52, č. 4, s. 279–296. Dostupné z DOI: [10.3414/ME12-01-0083](https://doi.org/10.3414/ME12-01-0083).
12. SMUTNÝ, Jaroslav; PAZDERA, Luboš. *Časove frekvenční analýza reálných signálů*. 1. vyd. Brno: ECON publishing, s.r.o., 2003. ISBN 80-86433-23-4.
13. GAO, Robert X.; YAN, Ruqiang. Non-stationary signal processing for bearing health monitoring. *International Journal of Manufacturing Research*. 2006, roč. 1, č. 1, s. 18–40. Dostupné z DOI: [10.1504/IJMR.2006.010701](https://doi.org/10.1504/IJMR.2006.010701).
14. *Time-frequency analysis of EEG data*. The Netherlands, 1999-2020. Dostupné také z: <http://www.fieldtriptoolbox.org/workshop/oslo2019/timefrequency/>.
15. CHUN-LIN, Liu. A Tutorial of the Wavelet Transform. *NTUEE*. 2010.
16. VALENS, Clemens. *A Really Friendly Guide to Wavelets*. 1999.
17. ADDISON, Paul S. *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*. Second edition. CRC press, 2017. ISBN 9781482251326.
18. HOEY, Gert Van; PHILIPS, Wilfried; LEMAHIEU, Ignace. Time-Frequency Analysis of EEG Signals. *Proceedings of the ProRISC Workshop on Circuits, Systems and Signal Processing*. 1997, s. 549–553.
19. BAI, Aleksander; FUGLERUD, Kristin S. Method for semi-automated evaluation of userexperience using brain activity. *Studies in health technology and informatics*. 2018, roč. 256, s. 811–820.
20. OOSTENVELD, R.; FRIES, P.; MARIS, E.; SCHOFFELEN, J. M. FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data. *Computational Intelligence and Neuroscience*. 2011. Dostupné z DOI: [10.1155/2011/156869](https://doi.org/10.1155/2011/156869).
21. GRANT, Michael; BOYD, Stephen. *MATLAB, version R2015b* [školní licence]. Natick, Massachusetts: The MathWorks Inc., 2015.
22. *Time-frequency analysis using Hanning window, multitapers and wavelets*. Dostupné také z: <http://www.fieldtriptoolbox.org/tutorial/timefrequencyanalysis/>.
23. *Short-time Fourier transform*. United States. Dostupné také z: <https://www.mathworks.com/help/signal/ref/stft.html>.
24. STANKOVIĆ, Ljubisa; DAKOVIĆ, Milos; THAYAPARAN, Thayananthan. *Time-frequency signal analysis with application*. 1st edition. Norwood: Artech house, 2013. ISBN 978-1-60807-651-2.

25. COHEN, Michael X. A better way to define and describe Morlet wavelets for time-frequency analysis. *BioRxiv* 397182. 2018. Dostupné z DOI: [⟨https://doi.org/10.1101/397182⟩](https://doi.org/10.1101/397182).
26. *Parametric and non-parametric statistics on event-related fields*. Dostupné také z: [⟨http://www.fieldtriptoolbox.org/tutorial/eventrelatedstatistics/⟩](http://www.fieldtriptoolbox.org/tutorial/eventrelatedstatistics/).
27. KIYMIK, M. Kemal; GULER, Inan; DIZIBUYUK, Alper; AKIN, Mehmet. Comparison of STFT and wavelet transform methods in determining epileptic seizure activity in EEG signals for real-time application. *Computers in Biology and Medicine*. 2005, roč. 35, č. 7, s. 603–616. Dostupné z DOI: [⟨10.1016/j.compbiomed.2004.05.001⟩](https://doi.org/10.1016/j.compbiomed.2004.05.001).
28. GERLA, Vaclav; SAIFUTDINOVA, Elizaveta; MACAS, Martin; MLADEK, A.; LHOTSKA, Lenka. P01-Comparison of short-time Fourier transform and continuous wavelet transform for frequency analysis of sleep EEG. *Clinical Neurophysiology*. 2018, roč. 129, č. 4. Dostupné z DOI: [⟨DOI:10.1016/j.clinph.2018.01.046⟩](https://doi.org/10.1016/j.clinph.2018.01.046).

## Příloha A: Zastoupení výkonu v jednotlivých pásmech

Tabulka A.1: Procentuální zastoupení výkonu v jednotlivých pásmech pro skupinu ANO s přítomností snění pro elektrody z parieto-okcipitální oblasti

Záznam	Fourier. transformace (%)				Vlnková transformace (%)			
	Alfa	Beta	Delta	Theta	Alfa	Beta	Delta	Theta
1	8,70	7,53	71,08	12,69	4,35	3,75	79,70	12,20
2	13,74	6,11	60,17	19,99	8,36	4,48	71,38	15,78
3	7,26	6,14	69,90	16,70	6,59	5,44	71,84	16,12
4	9,43	6,14	60,88	23,55	8,37	7,79	65,04	18,80
5	8,57	6,03	69,54	15,87	7,62	4,31	74,92	13,14
6	10,81	8,07	45,97	35,15	11,34	6,81	46,64	35,21
7	11,55	6,78	46,07	35,60	12,01	6,41	47,06	34,52
8	10,47	10,29	50,33	28,91	11,57	10,05	49,57	28,81
9	6,54	4,28	62,96	26,21	6,42	4,31	64,22	25,04
10	7,79	2,82	71,94	17,45	7,98	3,00	70,89	18,12
11	3,84	0,99	84,77	10,41	4,15	1,14	83,81	10,91
12	19,58	13,15	36,71	30,56	20,85	13,72	37,79	27,65
13	6,81	2,19	73,35	17,66	7,38	2,28	72,15	18,19
14	11,78	6,65	56,88	24,68	12,07	6,27	59,09	22,58
15	4,88	0,83	79,76	14,54	5,01	1,10	79,02	14,87
16	8,91	5,29	62,71	23,09	8,78	5,27	65,04	20,92
17	7,82	4,15	69,31	18,73	7,20	3,20	74,97	14,63
18	6,59	3,25	68,74	21,42	5,98	2,41	73,97	17,63
19	7,83	4,58	67,10	20,49	8,25	4,20	67,85	19,70
20	3,98	1,15	81,07	13,81	3,60	1,01	84,03	11,36
21	10,71	8,88	59,75	20,66	9,08	8,29	63,61	19,02
22	10,06	12,80	58,43	18,72	9,99	12,25	59,80	17,95
23	2,83	2,64	83,77	10,76	1,71	0,79	89,07	8,43
24	11,41	8,28	62,49	17,81	11,19	7,51	64,83	16,47
25	12,16	10,10	56,24	21,51	12,11	9,26	58,15	20,48
26	10,78	9,35	61,27	18,60	10,50	8,35	64,20	16,94
27	16,33	13,73	47,30	22,65	15,11	11,64	50,61	22,65
28	14,06	10,55	54,16	21,23	14,43	10,69	55,01	19,86
29	2,36	1,80	93,22	2,62	2,04	1,56	94,24	2,16
30	22,78	6,68	53,23	17,30	23,60	6,97	53,78	15,65
31	4,91	0,53	84,91	9,66	4,93	0,61	84,99	9,48
32	1,02	0,61	89,04	9,33	0,69	0,25	92,89	6,17
33	8,58	7,29	67,87	16,26	7,81	6,09	72,43	13,68

34	10,38	2,39	66,75	20,48	9,01	2,54	70,30	18,15
35	1,26	0,73	94,09	3,93	1,31	0,70	93,86	4,14
36	1,79	4,08	93,51	0,62	1,29	3,04	95,15	0,51
37	0,52	0,96	96,93	1,59	0,28	0,44	98,32	0,96
38	32,10	5,29	53,72	8,89	26,35	4,07	61,69	7,89
39	8,96	7,17	62,43	21,43	8,44	7,94	65,94	17,69
40	10,84	7,03	63,82	18,31	10,05	6,23	66,77	16,95
41	11,34	7,52	61,28	19,86	11,99	8,46	61,43	18,11
42	5,67	1,74	87,93	4,67	4,95	2,09	89,34	3,62
43	11,81	3,91	62,12	22,16	10,51	4,22	63,53	21,73
44	10,14	2,14	69,88	17,85	8,91	1,94	73,88	15,27
45	11,53	4,14	66,64	17,68	10,00	3,61	70,69	15,69
46	7,33	5,51	66,92	20,23	6,97	4,20	70,86	17,97
47	11,01	8,62	59,60	20,77	5,71	3,82	79,93	10,54
48	10,19	8,54	62,56	18,71	11,01	6,31	66,89	15,80
49	0,65	0,35	96,83	2,17	0,87	0,30	95,67	3,16
50	2,08	0,53	91,15	6,24	1,93	0,55	91,64	5,89
51	10,18	7,74	67,39	14,68	8,60	7,25	71,29	12,87
52	6,37	4,35	61,18	28,10	6,06	4,14	65,31	24,49
53	13,66	5,72	44,36	36,26	13,82	5,55	44,81	35,82
54	9,71	6,20	50,58	33,51	9,72	7,46	51,12	31,70
55	6,81	4,25	75,56	13,39	5,39	3,84	78,99	11,77

Tabulka A.2: Procentuální zastoupení výkonu v jednotlivých pásmech pro skupinu NE bez přítomnosti snění pro elektrody z parieto-okcipitální oblasti

Záznam	Fourier. transformace (%)				Vlnková transformace (%)			
	Alfa	Beta	Delta	Theta	Alfa	Beta	Delta	Theta
1	10,44	7,99	60,52	21,04	10,65	7,22	61,20	20,93
2	5,02	7,39	64,26	23,34	4,91	6,35	66,38	22,36
3	7,04	4,46	68,88	19,63	6,16	3,27	72,70	17,87
4	10,20	7,08	66,02	16,70	10,72	8,86	66,08	14,34
5	12,88	10,89	44,53	31,70	15,10	9,91	45,10	29,90
6	3,08	0,69	84,87	11,36	2,55	0,68	87,67	9,10
7	0,43	0,25	98,34	0,98	0,51	0,28	98,24	0,97
8	6,89	3,18	61,71	28,22	6,46	2,89	65,73	24,92
9	3,35	0,79	79,15	16,71	2,12	0,53	86,05	11,29
10	2,48	0,86	84,82	11,85	2,24	0,74	86,39	10,64
11	2,02	1,13	90,37	6,48	1,17	0,80	94,28	3,75

12	2,04	2,65	87,51	7,80	1,55	0,98	91,19	6,28
13	2,92	0,83	80,44	15,81	2,51	0,64	83,40	13,46
14	11,56	4,96	65,12	18,36	10,86	4,49	68,81	15,84
15	4,11	1,72	81,08	13,09	3,52	1,40	84,31	10,77
16	6,70	1,99	73,01	18,30	6,08	1,75	76,59	15,58
17	4,67	2,27	89,74	3,31	2,30	1,23	94,64	1,82
18	11,78	7,99	55,23	24,99	13,29	7,27	54,61	24,83
19	6,37	8,41	74,46	10,75	5,65	7,45	77,75	9,15
20	7,78	3,15	70,23	18,84	8,20	3,07	70,06	18,67
21	6,56	4,01	71,68	17,74	6,66	3,88	70,94	18,51
22	22,65	5,33	51,89	20,14	22,63	4,94	52,30	20,13
23	10,12	9,78	61,51	18,59	10,28	9,21	62,75	17,76
24	10,49	4,87	63,94	20,70	11,08	4,71	62,93	21,28
25	9,39	8,67	60,59	21,35	9,07	8,32	61,75	20,86
26	12,74	11,12	55,73	20,41	14,08	11,66	54,98	19,27
27	9,34	8,04	66,10	16,53	10,98	6,76	66,38	15,88
28	8,12	8,35	63,08	20,46	6,89	7,05	68,09	17,96
29	3,87	1,32	89,45	5,36	0,14	0,05	99,64	0,17
30	13,05	3,94	57,64	25,37	14,25	4,01	56,38	25,36
31	28,06	2,75	65,53	3,66	21,36	2,23	73,41	3,01
32	6,36	1,68	77,74	14,23	6,17	1,65	78,12	14,06
33	5,65	1,81	81,57	10,97	7,05	3,03	79,45	10,46
34	11,55	13,01	51,62	23,82	10,52	12,00	54,50	22,99
35	12,74	3,39	62,71	21,16	12,67	3,57	66,05	17,71
36	16,40	5,37	52,69	25,54	16,41	5,32	53,77	24,50
37	9,23	4,41	61,31	25,05	9,41	4,55	61,03	25,01
38	15,49	4,93	56,08	23,51	15,16	4,71	56,58	23,55
39	1,86	1,19	91,68	5,27	1,22	0,74	94,10	3,94
40	0,07	0,16	99,66	0,11	0,05	0,09	99,79	0,07
41	15,41	3,58	56,34	24,67	15,31	4,19	56,20	24,30
42	0,30	0,79	98,64	0,27	0,21	0,53	99,07	0,19
43	11,70	7,17	63,18	17,95	8,17	5,72	73,26	12,85
44	3,09	2,52	85,27	9,12	2,47	2,10	88,03	7,40
45	3,75	2,16	81,94	12,15	3,78	2,02	82,02	12,17
46	10,76	4,04	67,56	17,65	6,95	2,42	80,26	10,36
47	9,07	2,48	68,83	19,62	7,87	2,29	71,52	18,31
48	1,77	0,65	90,88	6,69	1,42	0,52	92,87	5,19
49	1,14	0,42	92,91	5,53	1,13	0,43	93,10	5,35

50	1,25	0,41	92,54	5,80	1,07	0,35	94,09	4,49
51	1,65	0,66	90,73	6,96	1,51	0,63	91,29	6,58
52	19,90	5,54	47,85	26,70	18,97	5,59	48,08	27,35
53	1,37	0,27	96,26	2,11	1,07	0,19	97,14	1,60
54	8,42	1,71	73,39	16,48	8,68	1,68	72,20	17,45
55	24,09	6,32	43,21	26,38	25,07	6,00	43,52	25,41
56	8,20	3,20	67,88	20,73	7,84	3,24	68,59	20,32
57	14,60	2,70	73,69	9,02	0,79	0,15	98,51	0,55
58	5,68	2,68	74,15	17,49	5,92	2,77	73,95	17,37
59	10,00	5,75	67,78	16,48	7,03	6,28	72,31	14,38
60	5,20	2,30	78,34	14,15	5,41	2,36	77,07	15,16
61	8,14	4,84	67,51	19,50	9,42	4,44	67,40	18,73
62	7,52	1,95	86,30	4,22	5,87	1,56	89,29	3,28
63	11,07	3,58	62,07	23,28	10,69	3,32	63,64	22,36
64	3,34	0,82	86,10	9,74	3,76	0,79	85,77	9,69
65	1,86	1,39	95,74	1,00	0,10	0,08	99,77	0,05
66	18,81	8,83	48,31	24,05	17,54	8,66	51,65	22,15
67	1,95	0,36	91,55	6,14	1,83	0,44	91,89	5,84
68	5,95	3,53	82,20	8,33	4,24	2,26	87,42	6,07
69	6,42	3,48	75,01	15,08	5,30	3,24	77,99	13,47
70	2,58	0,52	89,17	7,73	2,51	0,60	89,85	7,04
71	4,12	5,79	70,63	19,46	4,38	5,47	71,68	18,47

## **Příloha B: Obsah přiloženého CD**

1. Elektronická verze bakalářské práce
2. Zadání práce
3. Abstrakt česky
4. Abstrakt anglicky
5. Klíčová slova
6. Skripty
7. Informace k přiloženým skriptům
8. Obrázky: topografické mapy, závislosti  $t$  hodnot na čase
9. Informace k přiloženým obrázkům
10. Ukázková data