



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## AUTOMATICKÁ KLASIFIKACE SPÁNKOVÝCH FÁZÍ Z POLYSOMNOGRAFICKÝCH DAT

AUTOMATIC SLEEP SCORING USING POLYSOMNOGRAPHIC DATA

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Eva Vávrová

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina

BRNO 2016



# Diplomová práce

magisterský navazující studijní obor **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

**Studentka:** Bc. Eva Vávrová

**ID:** 147503

**Ročník:** 2

**Akademický rok:** 2015/16

## NÁZEV TÉMATU:

### Automatická klasifikace spánkových fází z polysomnografických dat

#### POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s metodami pro klasifikaci spánkových fází na základě analýzy polysomnografických záznamů pacientů. 2) Proveďte výpočet vybraných parametrů z alespoň dvou druhů signálů snímaných v průběhu různých spánkových fází. Použijte signály dostupné v databázi na ÚBMI. Pomocí statistické analýzy vyberte parametry vhodné pro následnou automatickou klasifikaci spánkových fází. 3) Na základě literární rešerše a výsledků analýzy jednotlivých parametrů EEG navrhnete postup pro následnou klasifikaci. 4) Realizujte navržený klasifikační postup a otestujte ho na dostupných záznamech. 5) Proveďte hodnocení úspěšnosti klasifikace a porovnejte dosažené výsledky s dostupnými údaji z literatury. Dosažené výsledky diskutujte.

#### DOPORUČENÁ LITERATURA:

[1] SÖRNMO, Leif a Pablo LAGUNA. Bioelectrical signal processing in cardiac and neurological applications. Academic Press, 2005, 688 s. ISBN 978-0-12-437552-9.

[2] MOSER, Doris et al. Sleep classification according to AASM and Rechtschaffen & Kales: Effects on Sleep Scoring Parameters. Sleep. 2009, č. 32, s. 139-149. ISSN 1550-9109.

**Termín zadání:** 8.2.2016

**Termín odevzdání:** 29.7.2016

**Vedoucí práce:** Ing. Marina Ronzhina

**Konzultant diplomové práce:**

**prof. Ing. Ivo Provazník, Ph.D., předseda oborové rady**

#### UPOZORNĚNÍ:

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

## **ABSTRAKT**

Tato diplomová práce se zabývá analýzou polysomnografických záznamů, která je založená na výpočtu vybraných parametrů v časové, frekvenční a časově-frekvenční oblasti. Parametry jsou počítány z 30s úseků EEG, EMG a EOG signálů snímaných v průběhu různých spánkových fází. Pomocí statistické analýzy jsou vybrány parametry, které jsou vhodné pro následnou automatickou klasifikaci spánkových fází, která je zrealizována pomocí umělé neuronové sítě, k-NN klasifikátoru a lineární diskriminační analýzy. V rámci této práce byl vytvořen program s grafickým uživatelským rozhraním v prostředí MATLAB.

## **KLÍČOVÁ SLOVA**

Spánkové fáze, polysomnografie, analýza PSG dat, automatická klasifikace, umělá neuronová síť, k-NN klasifikátor, diskriminační analýza

## **ABSTRACT**

The thesis is focused on analysis of polysomnographic signals based on extraction of chosen parameters in time, frequency and time-frequency domain. The parameters are acquired from 30 seconds long segments of EEG, EMG and EOG signals recorded during different sleep stages. The parameters used for automatic classification of sleep stages are selected according to statistical analysis. The classification is realized by artificial neural networks, k-NN classifier and linear discriminant analysis. The program with a graphical user interface was created using Matlab.

## **KEYWORDS**

Sleep stages, polysomnography, PSG data analysis, automatic classification, artificial neural network, k-Nearest Neighbours classifier, discriminant analysis

VÁVROVÁ, E. *Automatická klasifikace spánkových fází z polysomnografických dat*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2016. 76 s. Vedoucí diplomové práce Ing. Marina Ronzhina.

## **PROHLÁŠENÍ**

Prohlašuji, že svou diplomovou práci na téma Automatická klasifikace spánkových fází z polysomnografických dat jsem vypracovala samostatně pod vedením vedoucí diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících 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, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne .....

.....  
(podpis autora)

## **PODĚKOVÁNÍ**

Děkuji vedoucí diplomové práce Ing. Marině Ronzhině, za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne .....

.....  
(podpis autora)

## Obsah

1	Úvod .....	8
2	Polysomnografie .....	9
2.1	Hodnocení polysomnografického záznamu .....	9
2.2	Elektroencefalografie .....	12
2.3	Elektrookulografie .....	13
2.4	Elektromyografie .....	14
3	Automatická klasifikace spánkových fází .....	16
3.1	Předzpracování .....	16
3.2	Extrakce příznaků .....	17
3.2.1	Analýza v časové oblasti .....	17
3.2.2	Analýza ve frekvenční oblasti .....	19
3.2.3	Analýza v časově-frekvenční oblasti .....	21
3.3	Metody klasifikace dat .....	23
3.3.1	Neuronové sítě .....	23
3.3.2	Shluková analýza .....	26
3.3.3	k – nejbližších sousedů .....	26
3.3.4	Diskriminační analýza .....	27
3.3.5	Rozhodovací stromy .....	28
3.3.6	Metoda podpůrných vektorů .....	28
4	Analýza PSG signálů ze studie RELIEF .....	30
4.1	Analyzovaná data .....	30
4.2	Metody statistické analýzy .....	31
4.3	Vybrané příznaky v časové oblasti .....	33
4.4	Vybrané příznaky ve frekvenční oblasti .....	37
4.5	Vybrané příznaky v časově-frekvenční oblasti .....	40
4.6	Výsledné vybrané příznaky .....	45
5	Klasifikace PSG signálů .....	47
5.1	Vícevrstvá neuronová síť .....	47
5.1.1	Praktická realizace neuronové sítě .....	48
5.1.2	Klasifikace W, N3 a REM fáze .....	49
5.1.3	Klasifikace všech spánkových fází .....	53
5.2	k-NN klasifikátor .....	57
5.3	Lineární diskriminační analýza .....	59
6	Popis programu v prostředí Matlab .....	61
6.1	Panel <i>Signal</i> .....	62
6.2	Panel <i>Parameters</i> .....	63
6.3	Panel <i>Classification</i> .....	65
7	Zhodnocení výsledků klasifikace .....	68
8	Závěr .....	70
9	Literatura .....	71

10	Seznam symbolů, veličin a zkratk .....	75
11	Přílohy.....	76

# 1 ÚVOD

V současné době narůstá počet lidí trpících poruchami spánku. Proto stále více nabývá na významnosti analýza a hodnocení polysomnografických záznamů. Velkým problémem stále zůstává vizuální hodnocení těchto záznamů, jelikož se jedná o časově náročný proces i pro zkušeného specialistu a navíc je ovlivněn značnou mírou subjektivity. Proto v posledních letech dochází k rozvoji metod sloužící k automatické klasifikaci spánku.

Diplomová práce se v teoretické části věnuje polysomnografii. Jedná se o základní metodu, která se používá při vyšetření poruch spánku a bdění. Tato metoda snímá během spánku několik parametrů, ale v této práci budeme vycházet pouze z EEG, EMG a EOG záznamů. Následuje kapitola o automatické klasifikaci spánkových fází, která se dělí na předzpracování, extrakci příznaků a samotnou klasifikaci spánkových fází. Zde jsou zmíněny základní klasifikátory, které se dle studia literatury nejčastěji používají. Z teoretické části práce vychází program vytvořený v programovém prostředí Matlab, který byl použit pro analýzu a klasifikaci dat. Program byl doplněn o grafické uživatelské rozhraní.

Praktická část práce se zabývá samotnou analýzou vybraných polysomnografických záznamů, které pocházejí z dostupné databáze na ÚBMI. Z ní byla použita data šesti pacientů. Analýza je prováděna u vybraných příznaků v časové, frekvenční i časově-frekvenční oblasti. Pomocí statistické analýzy, konkrétně Kruskal-Wallisova testu, a selekce příznaků pomocí dopředného selekčního algoritmu, jsou vybrány příznaky, které jsou použity pro automatickou klasifikaci jednotlivých spánkových fází. Automatická klasifikace je zrealizována pomocí umělé neuronové sítě, k-NN klasifikátoru a lineární diskriminační analýzy ve dvou variantách, které se liší počtem klasifikovaných fází.



## 2 POLYSOMNOGRAFIE

Polysomnografie (PSG) je metoda, která sleduje během spánku řadu tělesných funkcí. Obvykle se jedná o celonoční simultánní záznam mnoha parametrů. Mezi základní patří: EEG (elektroencefalogram), EOG (elektrookulogram) a EMG (elektromyogram svalů brady). Polysomnografické vyšetření nezahrnuje pouze tyto tři základní parametry, ale také souběžně zaznamenává další [1]:

- EMG svalů bérce
- EKG (elektrokardiogram)
- saturaci hemoglobinu kyslíkem
- proud vzduchu při dýchání, dýchací úsilí (pohyby hrudníku a břicha)
- dýchací zvuky, polohu těla, záznam obrazu (videopolysomnografie).

Polysomnografie patří mezi nejpřínosnější diagnostickou metodu, která se používá při vyšetřování poruch spánku a bdění a dýchacích poruch při spánku. Na základě analýzy získaných dat je tak možné rozlišit jednotlivé spánkové fáze a typ poruchy. Pro PSG se standardně používá 14 kanálů [2]:

- 4 pro snímání EEG,
- 1 pro záznam dýchání,
- 1 kanál pro pohyby brady, EMG pro pohyby nohou, EOG pro pohyby očí,
- 1 pro EKG,
- 1 pro saturaci kyslíku,
- 1 pro pohyb hrudní stěny,
- 1 pro pohyb břišní stěny.

V této práci budeme využívat 1-kanálový EEG, EOG a EMG (pro pohyb brady) záznam. Proto si tyto signály v následujících kapitolách blíže představíme.

### 2.1 Hodnocení polysomnografického záznamu

Hodnocení (skórování) polysomnografického záznamu je standardizováno. V roce 1968 vznikl R&K (Rechtschaffen a Kales) standard, který byl celosvětově akceptován a který se stal na 40 let jediným uznávaným. Od roku 2007 je však postupně nahrazován tzv. americkým standardem AASM (angl. American Academy of Sleep Medicine). [3]

#### Spánkové fáze podle AASM standardu

Jak ukazuje tab. 1, podle AASM standardu se kromě fáze bdělosti (angl. Wake, W) spánek rozděluje do několika fází: REM (angl. Rapid Eye Movements) a NREM (angl. non-Rapid Eye Movements), který se dále dělí na N1, N2 a N3 fázi. Oproti R&K

standardu se nerozlišují zvláště úseky pohybových artefaktů (angl. movement time, MT) a spánek NREM je místo na čtyři fáze (S1-S4) rozdělen pouze na tři. S3 a S4 fáze jsou nahrazeny fází N3. Jednotlivá spánková stádia se hodnotí po tzv. epochách o délce trvání 30 s. Vyskytují-li se během jedné epochy dvě a více spánkových fází, je epocha označena podle časově převládající fáze. Informace v této kapitole byly čerpány z [2]-[4].

Tab. 1 R&K a AASM standardy pro hodnocení polysomnografických záznamů

Standard	R&K	AASM
Délka epochy	20 s nebo 30 s	30 s
Spánkové fáze	MT, W, NREM (S1-S4), REM	W, N1, N2, N3, REM

### *Bdělost*

Můžeme ji rozdělit na nerelaxovanou a relaxovanou. Při nerelaxované se EEG vyznačuje vysokou desynchronizací záznamu a vlnami beta o frekvenci 18 – 25 Hz a napětím 10 – 30  $\mu$ V. EMG se značí vysokou aktivitou, jejíž intenzita je závislá na aktivaci mimických svalů.

Při relaxované bdělosti se zavřenýma očima se na EEG objevují vlny alfa o frekvenci 8 – 12 Hz a napětí 20 – 40  $\mu$ V, dále vlny beta a jednotlivé vlny theta. EMG se vyznačuje kontinuální tonickou svalovou aktivitou o vysoké intenzitě, která opět závisí na aktivaci mimických svalů. Pro EOG jsou při nerelaxované i relaxované bdělosti typické rychlé sledovací pohyby nebo naopak žádný pohyb.

### *Spánek N1*

Na EEG se čteně vyskytují vlny theta o frekvenci 4 – 7 Hz a nízké amplitudě 50 – 70  $\mu$ V, naopak vlny alfa chybí ve většině epochy. Ve spánkové fázi N1 se navíc mohou vyskytnout ostré vertexové vlny. Na EOG se objevují pomalé konjugované oční pohyby a na EMG je jako u bdělosti kontinuální tonická svalová aktivita avšak nižší intenzity.

### *Spánek N2*

V této fázi se kromě theta vln (4 – 7 Hz) o nízké a střední amplitudě vyskytují spánková vřetena a K-komplexy.

Spánková vřetena jsou skupiny vln o vzrůstající a klesající amplitudě (vřetenovitý charakter) o frekvenci 12 – 14 Hz a délce trvání větší než 0,5 s. U dospělého člověka se objevují s frekvencí 3 – 8 za minutu, ve stáří frekvence i doba trvání klesá.

Spánková vřetena jsou doprovázena K-komplexy, což jsou bifázické pomalé vlny o délce trvání minimálně 0,5 s. Začínají vysokou pomalou ostrou negativní vlnou, která je následována pozitivní vlnou menší amplitudy. K-komplexy se vyskytují většinou jednou až třikrát za minutu. Spánková vřetena se často objevují před nebo za K-komplexem nebo v jeho průběhu. Avšak vždy platí, že časový odstup K-komplexů a spánkových vřeten musí být maximálně tři minuty. Během N2 spánku se oční bulby nepohybují, navíc v EOG lze dobře rozlišit K-komplexy a spánková vřetena, jelikož se jejich maximum nachází nad frontálním lalokem. V EMG se nachází opět kontinuální tonická svalová aktivita, ale nižší intenzity než v předchozích fázích.

### *Spánek N3*

Tento spánek bývá nazýván jako pomalý nebo delta spánek, jelikož pro tuto fázi jsou typické delta vlny o frekvenci 2 Hz a nižší a o minimální amplitudě 75  $\mu$ V. Během tohoto hlubokého spánku se v omezené míře mohou vyskytovat spánková vřetena a K-komplexy. Oční bulby se i zde nepohybují a svalová tonická aktivita nabývá ještě nižších intenzit než ve fázi N2.

### *Spánek REM*

REM spánek se vyznačuje nízkovoltážní desynchronizovanou EEG aktivitou, která připomíná záznam spánku N1 nebo nerelaxovanou bdělost. Přítomny jsou vlny theta a alfa. Spánková vřetena a K-komplexy se zde nevyskytují. Pro tuto fázi jsou typické nepravidelné, rychlé oční pohyby všemi směry. Na EMG se nepravidelně mohou objevit krátké záškuby, jinak zde není žádná kontinuální tonická svalová aktivita.

### **Architektura spánku**

Spánek je cyklicky uspořádaný. Jednotlivé spánkové fáze se vyskytují v cyklech, které se u normálně spících dospělých opakují po 90 – 110 minutách. Přechází-li člověk ze stavu bdění do dřímoty, objeví se u něj fáze N1. Jedná se o povrchní, lehký spánek, typické jsou pomalé oční pohyby, dochází k poklesu dechové a tepové frekvence a k relaxaci svalů. Mohou se zde objevovat náhlé a rychlé svalové záškuby.

Není-li člověk vyrušen, přechází do stádia N2, což je další fáze lehkého spánku. Svalové napětí pomalu klesá, elektrická aktivita mozku se dále zpomaluje a oční bulby se nepohybují.

Člověk upadá s přechodem do N3 do hlubokého spánku, kde dochází k dalšímu zpomalení elektrické činnosti mozku a výraznému uvolnění kosterního svalstva. Cyklus je zakončen REM spánkem, před ním se ještě krátce objeví N2 fáze, případně N1 fáze nebo bdělost. V REM fázi dochází k úplnému svalovému uvolnění a k rychlému pohybu očních bulbů. Tento cyklus je během noci několikrát opakován.

V prvním cyklu je převážně zastoupen spánek N3, naopak REM spánek zcela chybí nebo je velmi krátký. V dalších cyklech spánku N3 ubývá a naopak začíná přibývat REM a N2 fáze. Procentuální zastoupení jednotlivých spánkových fází u mladého dospělého člověka by mělo být následující: bdělost a N1 fáze méně než 5 %, N2 fáze 40 – 45 %, N3 fáze 20 – 25 % a REM spánek 20 – 25 %. S přibývajícím věkem se snižuje podíl hlubokého spánku a zvyšuje se množství N1 spánku a bdělosti. Naopak u dětí je vyšší podíl REM a N3 spánku.

Architektura spánku se dá hodnotit z tzv. hypnogramu. Jedná se o grafické vyjádření postupné sekvence jednotlivých spánkových fází během noci. [2]

## **2.2 Elektroencefalografie**

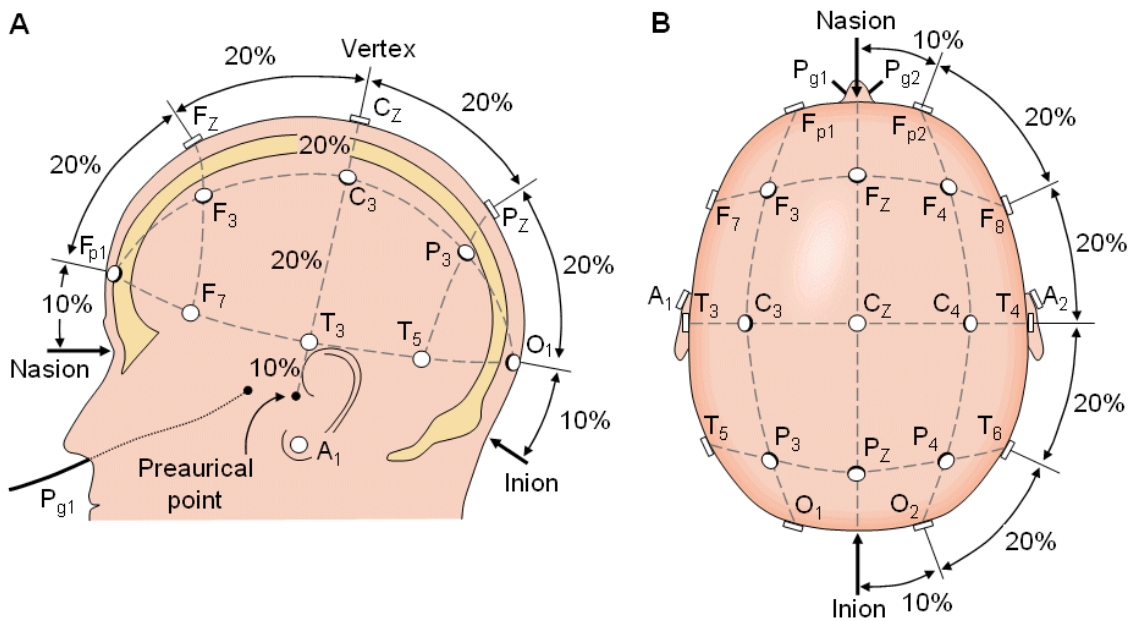
Elektroencefalografie je diagnostická metoda, která umožňuje snímat a zaznamenávat elektrickou aktivitu mozku. Podle místa snímání ji dělíme na neinvazivní a invazivní. Při neinvazivním snímání jsou signály zaznamenávány z povrchu hlavy pomocí

povrchových elektrod, při invazivním snímání jsou používány podpovrchové jehlové elektrody. Speciálním případem je invazivní metoda elektrokortikografie, kdy dochází ke snímání signálu z povrchu mozkové kůry. Záznamem vyšetření je elektroencefalogram (EEG). Informace ve zbylé části kapitoly byly čerpány z [5],[7].

### Snímání EEG

V klinické praxi se při snímání elektrické aktivity mozku z povrchu hlavy používá mezinárodní systém rozložení elektrod, který se nazývá „10/20“. Na obr. 1 je zobrazeno rozložení elektrod podle tohoto systému, kdy vzdálenosti mezi jednotlivými elektrodami jsou rozděleny na úseky o velikosti 10 % a 20 %. Krajní polohy ohraničují nasion (prohlubeň u kořene nosu v úrovni očí), inion (výstupek ležící uprostřed na týlní kosti) a body před každým ušním boltcem v úrovni nasionu.

Celkově se používá 21 elektrod, z toho 19 elektrod je umístěno na povrchu lebky a zbylé dvě na ušních boltcích. Elektrody jsou označeny kombinací jednoho nebo dvou písmen a čísla v podobě dolního indexu. Čísla označují hemisféry (sudá pravou a lichá levou hemisféru). Písmena souvisí s lebeční oblastí, kde je elektroda umístěna: F – frontální (čelní), Fp – frontopolární (přední, kolem pomyslného pólu), C – centrální (střední, na vrcholu lebky), P – parietální (temenní), T – temporální (spánková), O – okcipitální (týlní). Referenční elektrody na uších jsou označeny A1 (levý ušní lalůček) a A2 (pravý lalůček).



Obr. 1 Mezinárodní systém zapojení elektrod „10/20“ [1]

### Charakteristika EEG signálu

U EEG signálu snímaného z povrchu hlavy se špičkové napětí pohybuje v rozmezí 20 – 300  $\mu$ V. Frekvenční rozsah signálu je 0,5 – 70 Hz. V současné době se pro potřeby klinické diagnostiky využívá pásmo 0,5 – 30 Hz, kde je soustředěn největší výkon

signálu. EEG signál je rozdělen do čtyř základních frekvenčních pásem označených podle písmen řecké abecedy alfa, beta, gama a delta. Nejmenší hodnotitelnou jednotkou EEG je tzv. grafoelement. Lze rozlišit dva základní druhy grafoelementů: vlny a hroty. Sled po sobě jdoucích vln je nazýván rytmem, který vyjadřuje základní aktivitu mozku.

### *Rytmy EEG*

Jak již bylo uvedeno, rozlišujeme čtyři základní rytmy [5],[6]:

- **Delta rytmus** (0,5 – 4 Hz) je fyziologický jen v časném dětství a v dospělosti za hlubokého spánku, popř. v transu a hypnóze. V ostatních případech se téměř vždy jedná o patologický projev. Ve spánku může tento rytmus dosahovat amplitudy až 100  $\mu\text{V}$ .
- **Theta rytmus** (4 – 8 Hz) je považován za patologický, je-li jeho amplituda alespoň dvakrát vyšší než alfa aktivita, nebo vyskytuje-li se jen na jednom místě (ložiskově). Fyziologicky se vyskytuje u dětí a v mělkých stádiích stánku, kde přechází v aktivitu delta. Jeho amplituda je až 150  $\mu\text{V}$ .
- **Alfa rytmus** (8 – 13 Hz) je nejlépe vyjádřen nad týlními oblastmi. Tlumí se zrakovými vjemy (otevřením očí) a zvýšenou pozorností. Proto je alfa aktivita nejvíce patrna při zavřených očích. Je projevem klidové aktivity mozku ve stavu relaxované bdělosti, v klidu ležícího člověka se zavřenýma očima. Jeho amplituda bývá 20 až 50  $\mu\text{V}$ .
- **Beta rytmus** (13 – 30 Hz) mívá menší amplitudu než alfa rytmus, obvykle nepřesahuje 20  $\mu\text{V}$ . Bývá nejlépe vyjádřen pomocí čelních svodů. Většinou se netlumí otevřením očí nebo pozorností.

## 2.3 Elektrookulografie


Elektrookulografie je diagnostická metoda, která snímá elektrickou aktivitu očí. Využívá se toho, že oční rohovka má kladný elektrický potenciál a sítnice naopak záporný. Vzniká rozdíl potenciálů, který při změnách polohy oka způsobuje změny v elektrostatickém poli. K měření a registraci těchto změn elektrostatického pole očí slouží diagnostický přístroj elektrookulograf. Velikost těchto změn je registrována pomocí elektrod, které jsou umístěny na povrchu hlavy okolo očí. Záznam změn elektrického napětí se nazývá elektrookulogram (EOG).

Díky neinvazivnímu způsobu měření a možnosti sledování a vyhodnocování očních pohybů i při zavřených očích našla elektrookulografie široké uplatnění v lékařské diagnostice při sledování očních pohybů ve spánku.

### **Snímání elektrookulogramu**

Umístění elektrod, které snímají velikost elektrostatického pole, je zobrazeno na obr. 2. Lze měřit horizontální i vertikální složku záznamu. Pro měření horizontální složky EOG

jsou elektrody umístěny napravo a nalevo od koutků oka (elektroda 1 a 2). Pro měření vertikální složky jsou elektrody nad a pod okem (elektrody 3 a 4).



Obr. 2 Rozmístění elektrod při snímání EOG signálu [5]

Existují dva základní způsoby zapojení elektrod: unipolární a bipolární. Při unipolárním snímání rozlišujeme diferentní elektrodu a indiferentní elektrodu. Diferentní je vlastní měřicí elektrodou (elektroda 1,2,3,4), která je zpravidla maloplošná a je umístěna v elektricky aktivní oblasti. Indiferentní elektroda slouží jako srovnávací – referenční (elektroda 5). Tato elektroda je zpravidla velkoplošná, umístěna v elektricky neaktivní oblasti, nejčastěji uprostřed čela, popřípadě na ušním lalůčku či na krku.

Při bipolárním zapojení jsou obě elektrody označeny jako diferentní. Bývají maloplošné a umístěny v elektricky aktivní oblasti, kde snímají potenciálový rozdíl.

### **Charakteristika EOG**

EOG je z hlediska jeho charakteru zařazen do skupiny náhodných signálů. Jeho časový průběh nelze popsat matematickým vztahem. Popsat ho lze zprostředkovaně pomocí jeho charakteristik v časové a frekvenční oblasti. Amplitudová úroveň signálu má velikost řádově stovky  $\mu\text{V}$  až jednotky  $\text{mV}$ . Změna amplitudy EOG o  $20 \mu\text{V}$  je úměrná změně úhlu natočení oka o  $1^\circ$  v příslušném směru. Frekvenční rozsah je  $0,1 - 30 \text{ Hz}$  a má významnou stejnosměrnou složkou.

## **2.4 Elektromyografie**

Elektromyografie je diagnostická metoda, která snímá bioelektrické signály vznikající činností kosterního svalstva. Vzniklý záznam se nazývá elektromyogram (EMG). Samotné snímání signálu může být invazivní nebo neinvazivní. U PSG se využívá pouze neinvazivní snímání, proto bude dále blíže popsáno. Problematika snímání a zpracování EMG signálu nebyla dodnes v dostatečné míře standardizována, i když byla vydána různá doporučení. Proto se používají různé konfigurace lišící se počtem použitých elektrod a jejich uspořádáním.

Základní funkční jednotkou svalového aparátu je motorická jednotka (MJ). Ta se skládá z jednoho motoneuronu a souboru svalových vláken, které jsou motoneuronem

inervovány. Jeden sval může obsahovat 100 až 2 000 MJ a jeden motoneuron inervovat 5 až 1 000 svalových vláken. Somatická těla motoneuronů jsou umístěna v předním rohu páteřní míchy, odtud vycházejí nervová vlákna (axony). Axon každého motoneuronu se větví. Každá z těchto větví je zakončena nervosvalovou ploténkou, která inervuje svalové vlákno.

Akční potenciál, který se šíří z motoneuronu, se na svalová vlákna přenáší zmíněnou nervosvalovou ploténkou. Ta uvolňuje neurotransmitter, který podráždí membránu vlákna a způsobí jeho depolarizaci. Dochází k vybavení akčního potenciálu šířícího se z prostřední části vlákna oběma směry k jeho zakončení, díky postupnému depolarizování membrány lokálními proudy. Tím dochází ke stahu vlákna. V různých částech membrány svalového vlákna vzniká vlivem různých elektrických potenciálů elektrické pole. Měřením potenciálů tohoto pole získáváme EMG signál.


### **Snímání EMG signálu**

Při povrchovém snímání zaznamenáváme signál vzniklý činností velkého množství motorických jednotek. Signál zde dosahuje špičkové hodnoty do 10 mV. Frekvenční pásmo je značně omezeno objemem tkáně mezi elektrodami a svalovými vlákny a existencí rozhraní elektroda-pokožka. Horní hranice využitelného frekvenčního pásma je tím snížena na 500 Hz, frekvenční složky nacházející se nad touto hranicí již nelze odlišit od šumu. V oblasti 50 – 150 Hz leží hlavní část výkonového spektra signálu.

Při PSG je snímám EMG signál samovolných pohybů brady a signál dolní části nohou. Při snímání pohybů brady je využito trojice elektrod: referenční ve středu brady a dvou elektrod umístěných 2 cm pod bradou a 2 cm napravo/nalevo od středové linie. Signály dolní části nohou získáváme pomocí dvojic elektrod umístěných na předním holenním svalu každé nohy, jelikož tento sval nejlépe vypovídá o pohybech nohy a chodidla.

## 3 AUTOMATICKÁ KLASIFIKACE SPÁNKOVÝCH FÁZÍ

Automatickou klasifikaci spánkových fází na základě PSG dat dělíme do tří základních bloků [8]: předzpracování, extrakci příznaků a samotnou klasifikaci, viz obr. 3.



Obr. 3 Automatická klasifikace spánkových fází

### 3.1 Předzpracování

Prvním krokem je předzpracování PSG signálů, kde dochází k eliminaci artefaktů a dalších nežádoucích složek. Naopak některé zajímavé složky signálu jsou zvýrazněny. Nejčastějším typem předzpracování je filtrace, která potlačuje nežádoucí složky signálu, a současně co nejméně znehodnocuje užitečnou složku signálu. Za rušivou složku nejčastěji považujeme artefakty technické a biologické.

Technické artefakty mohou být způsobeny vlastním měřicím přístrojem, dále elektrodami a přívodními vodiči elektrod, kdy artefakty vznikají v důsledku pohybu elektrod, vzájemným pohybem přívodních vodičů elektrod nebo kvůli špatné elektrode (kolísání nulové izolinie). Mezi technické artefakty řadíme i artefakty z prostředí, které vznikají díky interferenci se zdroji elektrické energie nebo jiného elektromagnetického pole z okolí přístroje. Typickým příkladem je existence síťového rušení s kmitočtem 50 Hz. Do této skupiny řadíme i artefakty způsobené pohybem osob kolem pacienta a artefakty z okolních přístrojů (zvonění telefonu, vypnutí/zapnutí osvětlení, klimatizaci, činnost signalizačních systémů).

Druhou skupinou jsou biologické artefakty způsobené samotným pacientem. Jejich výskyt je častý, ovšem jejich zamezení je téměř nemožné. Mezi nejčastější artefakty řadíme: artefakty způsobené pohybem očí a mrkáním, svalové artefakty, elektrokardiografické artefakty a artefakty vzniklé v důsledku dýchání.

Oční artefakty, které vznikají pohybem očních bulbů nebo mrkáním, postihují hlavně EEG signál, zejména elektrody umístěné blízko očí (frontální a frontopolární). Těmito artefakty je zasaženo zejména delta a theta frekvenční pásmo. Avšak artefakty způsobené mrkáním se ve srovnání s očními pohyby vyznačují vyšší frekvencí (až do 20 Hz).

Svalové artefakty mohou být způsobeny svalovým napětím nebo svalovou aktivitou (pohyb hlavy, těla, končetin). Svalové artefakty se mohou projevit jako jednotlivé hroty, oscilace nebo kontinuální rušení. Frekvenční rozsah svalových artefaktů je široký, uvádí se pásmo 0,25 - 32 Hz.



Častá je přítomnost artefaktů způsobených elektrickou aktivitou srdečního myokardu, které jsou rytmické a synchronní s QRS komplexy elektrokardiogramu, jejich přítomnost je tak jednoduše detekovatelná.

Dýchání je vždy doprovázeno rytmickým pohybem hrudníku, krku a hlavy. Pohyb hlavy může způsobit pohyb elektrod používaných ke sledování PSG signálů. Dýchání tak zavádí pomalovlnné artefakty, které jsou synchronní s nádechem a výdechem.

Pro snížení vlivu výše zmíněných artefaktů lze použít různé výpočetní metody. K potlačení síťového brumu se využívá lineární filtrace typu pásmová zádrž. Lineární filtrace se také používá k potlačení svalových artefaktů, konkrétně typu dolní propust. Musíme opatrně volit mezní frekvenci, aby nedocházelo ke zkreslení ostrých hrotů a vln. K redukci očních a srdečních artefaktů se zejména volí adaptivní filtrování nebo korelační filtrace. Na výběr máme více možných metod, vždy je nutné brát zřetel na dostupná data a hardwarové/softwarové možnosti. [5][9][10]

## 3.2 Extrakce příznaků

Manuální klasifikace spánkových fází je založena na vizuálním hodnocení polysomnografických záznamů. Zkušený lékař je schopen analyzovat průběh signálu (i s případnými artefakty) vizuálně, a následně dané epoše přiřadit odpovídající spánkovou fázi. Při automatické klasifikaci musí být z vybraných signálů vypočtena sada relevantních parametrů (příznaků). Právě výběr vhodných příznaků je jedna z nejdůležitějších záležitostí automatické klasifikace.

Studie různých autorů ukazují, že existuje velké množství metod sloužících k získání rozdílných parametrů z PSG signálů. Hodnoty vyextrahovaných parametrů jsou individuální pro každou 30s epochu signálu, čehož se využívá při klasifikaci. Parametry získáváme pomocí analýzy signálů v časové, frekvenční či časově-frekvenční oblasti.

### 3.2.1 Analýza v časové oblasti

Účelem analýzy náhodných signálů v časové oblasti je najít vazby, popř. zjistit neexistenci takových vazeb, mezi hodnotami signálu v různých časových okamžicích (u jednotlivých spánkových fází). Pro analýzu EEG, EMG a EOG signálů v časové oblasti byly vybrány následující parametry [11]-[13]:

- **Směrodatná odchylka**

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad (1)$$

kde  $n$  je počet vzorků  $x_i$  měřeného signálu  $x$  v epoše a  $\bar{x}$  reprezentuje střední hodnotu signálu  $x$ .

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2)$$

- **Koeficient šikmosti** (skewness) měří asymetrii rozložení náhodné veličiny. Pokud jsou hodnoty náhodné veličiny rovnoměrně rozloženy vlevo a vpravo od střední hodnoty, je šikmost nulová. Při záporné šikmosti se vlevo od střední hodnoty vyskytují odlehlejší hodnoty než vpravo, u kladné šikmosti je tomu naopak.

$$skewness = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s^3}, \quad (3)$$

kde  $n$  je počet vzorků  $x_i$  měřeného signálu  $x$ ,  $\bar{x}$  je střední hodnota signálu a  $s$  je směrodatná odchylka.

- **Koeficient špičatosti** (kurtosis) určuje relativní strmost nebo plochost (příspěvek vzdálených hodnot) rozdělení náhodné veličiny v porovnání s normálním rozdělením. Normální rozdělení má špičatost rovnou 3. Rozdělení více náchylné k odlehlým hodnotám má špičatost vyšší než 3. Naopak špičatost menší než 3 udává menší náchylnost k odlehlým hodnotám (rozdělení je ploché).

$$kurtosis = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{s^4} - 3 \quad (4)$$

- **75. percentil** definuje hodnotu, pod kterou je umístěno 75 % hodnot náhodné proměnné. Je také nazýván jako horní kvartil nebo třetí kvartil a je definován jako:

$$card\{x(i)/x(i) < prctile75\} = \frac{75 * n}{100}, \quad (5)$$

kde  $n$  je počet vzorků  $x(i)$  signálu  $x$  v epoše a  $card$  udává počet prvků v sadě.

- **Entropie** (tzv. Shannonova entropie) je statistickou mírou neuspořádanosti, která je počítána z histogramu signálu během jedné epochy:

$$entr = - \sum_{j=1}^N \frac{n_j}{n} \ln \frac{n_j}{n}, \quad (6)$$

kde  $n$  je počet vzorků  $x(i)$  měřeného signálu  $x$  v epoše,  $N$  je počet tříd použitý při výpočtu histogramu a  $n_j$  je počet vzorků  $x(i)$ , jejichž hodnoty se nachází v příslušné  $j$ -té třídě.

### Hjorthovy parametry

Mezi Hjorthovy parametry patří aktivita, mobilita a složitost, které jsou počítány ze signálů na základě rozptylu a první a druhé derivace. Aktivita je definována jako rozptyl signálu, mobilita udává odhad střední (dominantní) frekvence signálu. Posledním z Hjorthových parametrů je složitost, která je odhadem šířky pásma signálu. Rozptyl je dán vzorcem [14]:

$$var = \frac{1}{n-1} \sum_{i=1}^n (x_i - x)^2. \quad (7)$$

- Aktivita

$$A = var(x), \quad (8)$$

- Mobilita

$$M = \sqrt{var(x')/var(x)}, \quad (9)$$

- Složitost

$$C = \frac{M(x')}{M(x)} = \sqrt{\frac{var(x'') * var(x)}{var(x')^2}}, \quad (10)$$

kde  $var(x)$  je rozptyl signálu  $x$ ,  $x'$  je první derivace a  $x''$  je druhá derivace signálu.

### 3.2.2 Analýza ve frekvenční oblasti

Spektrální analýza je výkonný analytický nástroj, který slouží k určení spektra nebo spektrální výkonové hustoty signálu. Matematickým základem metod spektrální analýzy jsou ortogonální transformace, které časovému průběhu signálu přiřazují spektrum a naopak spektru signál. Jednou z neznámějších transformací je Fourierova transformace, kterou si blíže představíme. [15]

#### Fourierova transformace

Základní vlastností každého signálu je jeho spektrum, které vyjadřuje obsah harmonických složek v signálu. Spektrum signálu se spojitým časem je vyjádřeno jeho Fourierovou transformací (FT), která je dána vztahem [16]:

$$F(w) = F\{f(t)\} = \int_{-\infty}^{\infty} f(t)e^{-j\omega t} dt, \quad (11)$$

kde  $F(w)$  je spektrum analogového signálu,  $F\{f(t)\}$  je FT funkce časově závislé funkce  $f(t)$  a  $w$  značí kmitočet.

Jelikož pracujeme s diskretními signály, je nutné použít modifikaci FT, známou jako diskretní Fourierova transformace (DFT), která přiřazuje signálové posloupnosti  $N$  vzorků v originální oblasti stejně dlouhou posloupnost ve spektrální oblasti. DFT je vyjádřena vztahem [17]:

$$DFT \{f_n\} = \left\{ F_k = \sum_{n=0}^{N-1} f_n e^{-jk\Omega nT} \right\}, \quad (12)$$

kde  $N$  je počet vzorků,  $\Omega$  je  $N$ -tina vzorkovacího kmitočtu,  $T$  značí vzorkovací periodu,  $n$  a  $k$  jsou celočíselné indexy a  $F$  jsou komplexní spektrální koeficienty.

Nevýhodou DFT je její časová náročnost, proto se pro její výpočet využívá efektivní algoritmus rychlé Fourierovy transformace (FFT). FT nám podává informace o frekvenčních složkách spektra, avšak chybí informace o jejich vývoji v čase.

U deterministických signálů spektrální analýza zjišťuje amplitudy a počáteční fáze harmonických složek signálu. Zatímco u náhodných signálů jde o odhad výkonů harmonických složek, tj. bez fázové informace. U náhodných signálů se tak místo pojmu spektrum zavádí spektrální výkonová hustota (PSD, z angl. power spectral density), která popisuje rozložení výkonu signálu v závislosti na frekvenci. Pro určení spektrální výkonové hustoty lze použít neparametrické metody, které jsou založeny na použití DFT, nebo parametrické metody založené na popisu signálu souborem parametrů. [15]

### **Odhad výkonových spekter metodou periodogramu**

Základní neparametrickou metodou pro odhad výkonového spektra je metoda periodogramu, která je definována vztahem:

$$S_x(f) = \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-j2\pi f n} \right|^2, \quad (13)$$

kde  $x$  je analyzovaný signál,  $N$  je počet vzorků,  $x(n)$  je  $n$ -tý vzorek signálu a  $f$  kmitočet signálu.

Odhad výkonového spektra podle vztahu (13) vychází pouze z jediné realizace analyzovaného signálu, proto odhadnutý periodogram vykazuje velký rozptyl. Přesnější odhad získáme průměrováním periodogramu přes  $M$  realizací signálu, kdy rozptyl odhadu klesá s počtem realizací  $M$ . Pokud máme pouze jednu realizaci signálu, vyhlazený odhad získáme váhovaným průměrováním dílčích periodogramů. Jedna z nejpoužívanějších metod průměrování periodogramu je Welchova metoda, která rozděluje dlouhý signál na  $K$  segmentů, které jsou považovány za jednotlivé realizace. [15][16]

### **Odhad výkonových spekter metodou korelogramu**

Metoda korelogramu je založena na diskrétním Wiener-Chinčinově vztahu. Prvním krokem je odhad váhované autokorelační funkce, následuje DFT odhadu autokorelační funkce. Metodu korelogramu můžeme aplikovat na jeden dlouhý signál nebo u stacionárního a ergodického signálu můžeme za jednotlivé realizace považovat dílčí úseky jednoho signálu. [16]

### **3.2.3 Analýza v časově-frekvenční oblasti**

EEG signál budeme navíc analyzovat v časově-frekvenční oblasti, při které získáváme informaci o změnách obsahu frekvenčních složek signálu v čase. V této práci si představíme dvě základní transformace sloužící k analýze signálu v časově-frekvenční oblasti, jsou jimi krátkodobá Fourierova transformace a vlnková transformace.

#### **Krátkodobá Fourierova transformace**

Základním principem krátkodobé Fourierovy transformace (angl. short-time Fourier transform, STFT) je rozdělení signálu na krátké úseky, ze kterých jsou odvozeny dílčí spektra. Jednotlivé úseky signálu jsou vymezené postupně se posouvajícím oknem zvolené délky. Na každém výřezu, u nichž se již předpokládá dostatečná stacionarita, je provedena Fourierova transformace. Krátkodobá Fourierova transformace je dána vztahem:

$$STFT(\tau, f) = \int_{-\infty}^{\infty} [x(t) \cdot w^*(t - \tau)] \cdot e^{-j2\pi ft} dt, \quad (14)$$

kde  $w$  je okénková funkce,  $*$  komplexní konjugace,  $t$  je čas,  $\tau$  je časové posunutí okénka,  $x(t)$  je časová reprezentace signálu a  $STFT(\tau, f)$  je časově-frekvenční reprezentace. [16][18]

Časová okna se mohou při posouvání překrývat, což umožňuje plynulejší sledování vývoje spektra v čase, avšak nedochází ke zlepšení z hlediska informačního. Délka okna se volí kompromisem, není možné současně zajistit vysoké časové i frekvenční rozlišení. Široké časové okno dává horší časové rozlišení, ale vysoké frekvenční rozlišení, při použití krátkého okna je tomu naopak.

Dílčí krátkodobá spektra se kvůli snazšímu sledování vývoje ve spektru sestavují do tzv. spektrogramů, souborů krátkodobých DFT spekter, které zachycují spektrální vývoj v čase jako 2D obraz. Na svislé ose je vynesena frekvence, na vodorovné ose časový vývoj a barva či úroveň jasu odpovídá amplitudě. [16]

#### **Vlnková transformace**

Obdobně jako STFT, také pomocí vlnkové transformace (ang. wavelet transform, WT) lokalizujeme výskyt frekvenčních složek zejména u nestacionárních signálů v čase. Základem vlnkové transformace je rozklad signálu pomocí bázevých funkcí – vlnky. Každá

vlnka má nenulové hodnoty jen na konečném časovém intervalu, působí tak pouze na odpovídající úsek analyzovaného signálu. Bázové funkce pokrývají po částech celý časový rozsah signálu, úplná informace je tak zachována. [17]

#### *Spojité vlnková transformace*

Spojité vlnková transformace (angl. continuous wavelet transform, CWT) je definována vztahem [17]:

$$S_{CWT}(a, \tau) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{1}{a} - \tau\right) dt, \quad (15)$$

kde  $x(t)$  je analyzovaný signál,  $a$  je dilatace (měřítko) mateřské vlnky  $\psi$  a  $\tau$  je časový posun.

Ze vztahu lze vidět, že hodnoty spektra (vlnkové koeficienty)  $S_{CWT}(a, \tau)$  jsou dány korelačním integrálem mezi analyzovaným signálem a bázovou funkcí. Skutečný tvar konkrétní vlnky závisí na parametru  $a$  i  $\tau$ . Parametr  $a$  udává časovou dilataci funkce, pro  $a > 1$  je vlnka natažena  $a$ -krát. Změna časového posunu  $\tau$  umožňuje postupně pokrýt pomocí vlnek konečného trvání celý časový rozsah signálu. I když výběr tvaru vlnky je značně volný, musí splňovat jisté požadavky. Pokud má být transformace inverzibilní, musí být bázové funkce navzájem ortogonální, musí mít nulovou střední hodnotu a být kompaktní v časové i frekvenční reprezentaci. Mezi standardní typy vlnek patří: Haarovy, Daubechiesové, biortogonální, tzv. coiflety a symplety. [17]

#### *Diskrétní vlnková transformace*

Spojité vlnková transformace generuje nadbytečné množství informace – vlnkových koeficientů, je tak výhodné redukovat počet hodnot měřítka a posunutí. Abychom získali diskrétní spektrální reprezentaci, počítají se pouze koeficienty odpovídající měřítkům  $a = 2^j$  a časovému posunu  $\tau = k2^j = ka$ , kde  $k, j \in \mathbb{Z}$ .


Pro výpočet diskrétní vlnkové transformace (angl. discrete wavelet transform, DWT) se používá algoritmus rychlé vlnkové transformace FWT, který využívá teorie zrcadlově kvadraturních filtrů QMF (typu dolní a horní propust). Pomocí filtrace dolní propustí, propouštějící složky o frekvencích mezi nulou a polovinou Nyquistova kmitočtu, získáváme koeficienty tzv. aproximace signálu. Filtrací horní propustí s propustným pásmem mezi polovinou Nyquistova kmitočtu a Nyquistovým kmitočtem obdržíme koeficienty detailů. Aproximace a detaily signálu jsou výstupními signály QMF. Jelikož jsou výstupy obou filtrů podvzorkovány na polovinu vstupních vzorků, je počet koeficientů transformace shodný s počtem vzorků vstupního signálu. Tento postup lze rekurzivně opakovat, na každé úrovni je počet vstupních vzorků poloviční oproti předchozí úrovni. Jelikož v žádné filtrační úrovni nedochází ke ztrátě informací, lze proces dekompozice v kterékoli úrovni zastavit. [17]

### 3.3 Metody klasifikace dat

Cílem klasifikace je rozdělení daných objektů do tříd, v našem případě přiřadit jednotlivým 30s epochám jednu ze spánkových fází. V této podkapitole si představíme základní a nejčastěji používané klasifikátory.

#### 3.3.1 Neuronové sítě

Jedním z nejpoužívanějších klasifikátorů uváděných v literatuře je neuronová síť. Základem matematického modelu neuronové sítě je formální neuron, který vychází z biologického neuronu, viz obr. 4. Formální neuron má  $n$  obecně reálných vstupů  $x_1, \dots, x_n$ , které modelují dendrity. Vstupy jsou ohodnoceny reálnými synaptickými váhami  $w_1, \dots, w_n$ , určující jejich propustnost. Do vztahu může být přidán tzv. bias  $w_0 = -h$  (práh neuronu se záporným znaménkem chápaný jako váha) odpovídající jednotkovému vstupu. Vážená suma vstupních hodnot vyjadřuje vnitřní potenciál  $\zeta$ . Hodnota potenciálu po dosažení tzv. prahové hodnoty  $h$  indikuje výstup neuronu  $y$ , který modeluje elektrický impuls axonu. [19]



Obr. 4 Schéma biologického neuronu (vlevo) a formálního neuronu (vpravo) [19]

Neuronová síť se skládá ze vzájemně propojených formálních neuronů, kdy výstup jednoho neuronu je vstupem do jednoho i více dalších neuronů. Architektura neuronové sítě je dána počtem neuronů a jejich vzájemných propojením. V neuronové síti rozlišujeme vstupní, pracovní (skryté) a výstupní neurony. Neuronové sítě mají schopnost učení, průběžně adaptují své parametry a strukturu, aby vyhovovaly zadaným požadavkům. Je nutné síť trénovat na takových vstupech, u kterých víme, do které třídy patří.

Při učení dochází nejprve k inicializaci vah a prahu, následně je předložena trénovací dvojice (vstupní vektor a jemu odpovídající výstup). Vypočítáme aktuální

výstup, který porovnáme s požadovaným výstupem. Podle zjištěné odchylky přizpůsobíme váhy. Učení probíhá v tzv. epochách, dochází k ukázaní všech učebních dvojic neuronové sítě. Pokud neskončila epocha učení, postup opakujeme, jinak učení ukončíme. Poté v dané epoše vyhodnotíme klasifikaci a ukončíme učení nebo zahájíme další epochu. Toto učení neuronové sítě probíhá s učitelem. Druhým typem učení je učení bez učitele. Síť s učitelem se snaží napodobit předkládané vzory, učí se z příkladů. Naopak u učení bez učitele obsahuje tréninková množina pouze vstupy sítě, síť sama organizuje tréninkové vzory (např. do shluků) a zjišťuje jejich souborné vlastnosti.

Po naučení neuronové sítě nastává fáze vybavování, kdy neuronové sítě předkládáme neznámý vzor (vstupní vektor  $x$ ), který nám zařadí do příslušné třídy. [19][20]

### 3.3.1.1 Vícevrstvá neuronová síť

U vícevrstvé neuronové sítě jsou neurony uspořádány do vrstev, mezi dvěma sousedními vrstvami dochází vždy k úplnému propojení neuronů, kdy každý neuron nižší vrstvy je spojen se všemi neurony vrstvy vyšší. Nikdy však nedochází ke spojení neuronů ve stejné vrstvě. Taková síť vždy obsahuje vstupní a výstupní vrstvu a může obsahovat i různý počet skrytých vrstev. Jednou z nejdůležitějších vlastností neuronových sítí je schopnost učení, v tomto případě se jedná o učení s učitelem. Princip tohoto učení byl popsán výše. [38]

#### Algoritmus zpětného šíření chyby

Algoritmus zpětného šíření chyby neboli backpropagation (BP) je učící algoritmus pro vícevrstvou síť, opět jsou předkládány vstupy a požadované výstupy. Cílem algoritmu je minimalizace rozdílu mezi výsledným a požadovaným výstupem pomocí úpravy vah. Adaptace vah probíhá zpětně, od výstupních vrstev ke vstupním. Pro učení pomocí BP je důležitý výběr aktivační funkce, která musí být diferencovatelná, spojitá a monotónně neklesající. Nejčastěji používanou aktivační funkcí je standardní (logická) sigmoida a hyperbolický tangens.

Učení sítě probíhá na trénovací množině  $T$ , která obsahuje vstupní vektor  $x$  a vektor výstupů  $d$ , tedy dvojici  $(x_p, d_p)$ . Chyba sítě nám definuje, jak se požadovaný a výsledný výstup liší. Celková chyba sítě je dána součtem parciálních chyb vzhledem k jednotlivým tréninkovým vzorům [19]:

$$E(w) = \sum_{k=1}^p E_k(w), \quad (16)$$

kde  $k$  je  $k$ -tý tréninkový vzor.




Parciální chyba sítě je pak definována jako [19]:

$$E_k(w) = \frac{1}{2} \sum_{j \in Y} (y_j(w, x_k) - d_{kj})^2, \quad (17)$$

kde  $d_{kj}$  je požadovaný výstup a  $y_j(w, x_k)$  je aktuální výstup pro vektor  $x_k$ .

K nalezení minimální chyby se používá tzv. gradientní metoda, která je zobrazena na obr. 5. Zde lze vidět vývoj chybové funkce  $E(w)$ , kde na ose  $x$  je vektor vah  $w$ . Na začátku jsou váhy  $w^{(0)}$  náhodně nastaveny blízko nuly, zde se předpokládá velká chyba funkce. V bodě  $w^{(0)}$  je sestrojen tečný vektor neboli gradient ke grafu chybové funkce. Při posunutí ve směru gradientu dolů o  $\epsilon$ , což je rychlost učení ( $0 < \epsilon < 1$ ), získáme novou konfiguraci. Po tomto posunutí získáváme menší chybovou funkci než v předcházejícím kroku:  $E(w^{(0)}) \geq E(w^{(1)})$ . Celý proces opakujeme do doby, kdy chybová funkce limitně dosáhne minima. Chyba funkce se již nezmenšuje a adaptace se tak zastaví. Hlavním problémem této metody je, že se může jednat pouze o lokální minimum, nikoli globální. [19][38]



Obr. 5 Gradientní metoda [38]

Kromě minimalizace chybové funkce je dalším problémem volba vhodné topologie. Ve většině případů se používá vícevrstvá topologie s jednou nebo dvěma skrytými vrstvami, je však potřeba vhodně volit počty neuronů v těchto skrytých vrstvách. Při učení pomocí algoritmu BP se příliš malá síť může zastavit v nějakém lokálním minimu a je potřeba tuto topologii doplnit o další skryté neurony. Na druhou stranu bohatá topologie často umožní nalézt globální minimum chybové funkce, avšak s větším počtem vah roste výpočetní náročnost. V praxi se topologie obvykle volí heuristicky, např. v první vnitřní vrstvě se volí o něco více neuronů než je vstupů a ve druhé vrstvě je počet neuronů dán aritmetickým průměrem mezi počtem výstupů a neuronů v první vnitřní vrstvě. [38]

### 3.3.2 Shluková analýza

Shluková analýza (angl. cluster analysis) je příznakově orientovaná metoda, kdy dochází k seskupování zkoumaných objektů do skupin na základě jejich podobnosti resp. rozdílnosti. Jedná se o učení bez učitele, nemáme žádnou apriorní informaci o objektech. Objekty (data) jsou popsány  $n$ -rozměrnými příznaky, pomocí nichž shluková analýza klasifikuje objekty do jednotlivých tříd (shluků) tak, aby objekty náležící do stejného shluky byly vzájemně podobní a zároveň nebyli příliš podobní s objekty mimo tento shluk. [15]

Metody shlukové analýzy rozdělujeme na hierarchické a nehierarchické. Hierarchické shlukovací metody seřazují shluky do hierarchické struktury, dělíme je na divizní – vycházíme z 1 shluku, který postupně dělíme a na aglomerativní, kdy vycházíme z jednotlivých objektů, které spojujeme. Hierarchické shlukování dává více alternativních řešení. Graficky je lze vyjádřit pomocí stromů – dendrogramů. Tato metoda je náročná na paměť a na dobu výpočtu, proto není vhodná pro velké soubory dat. Hierarchické metody byly překonány modernějšími postupy, např. nehierarchickými metodami.

Nehierarchické metody rozdělují objekty do  $k$  shluků kolem stanovených vzorů. Nejčastěji se používá metoda  $k$ -means (metoda  $k$ -průměrů). Algoritmus metody má následující kroky:

1. Zvolíme si  $k$  inicializačních shluků (nejčastěji náhodně).
2. Objekty se přemísťují do shluků s nejbližším těžištěm – centroidem.
3. Dochází k přepočítání jednotlivých centroidů shluků.
4. Body 2 a 4 se opakují do doby, kdy se složení shluků nemění.

Tímto způsobem se objekty přesouvají tak, aby variabilita uvnitř skupin byla co nejmenší a naopak variabilita mezi skupinami co největší. [15][20]

Další variantou metody  $k$ -průměru je fuzzy  $k$ -means algoritmus. Podle klasické teorie množin může prvek nabývat pouze dvou hodnot: 0 (prvek nepatří do množiny – třídy) a 1 (prvek patří do množiny). Taková klasifikace neumožňuje současné členství jednoho objektu v různých třídách. Tím vzniká problém u hybridních objektů, které lze přiřadit do více tříd s různým stupněm příslušnosti. Naopak u teorie fuzzy množin prvek nabývá hodnot z intervalu  $\langle 0,1 \rangle$ , a tím fuzzy množiny umožňují vícenásobné sdílení objektu ve více třídách (s různým stupněm členství). Toho využívá zmíněný fuzzy  $k$ -means algoritmus, kde každý objekt může náležet do více shluků s určitým stupněm příslušnosti mezi 0 a 1. [15]

### 3.3.3 $k$ – nejbližších sousedů

Patří mezi metody typu IBL (Instance Based Learning) neboli učení založené na instancích, které patří mezi jednoduché, přesto účinné nástroje strojového učení. Fungují na základě podobnosti nového objektu s objekty již známými. Algoritmy IBL jsou na pomezí mezi učením s učitelem a bez učitele. Jelikož je známa výstupní hodnota

u každého trénovacího prvku, zařadíme IBL mezi učení s učitelem. U základního algoritmu k-NN (angl. k-nearest neighbours) ovšem k žádnému učení nedochází. Učení zde představuje pouhé uložení všech trénovacích dat.

K-NN je založený na podobnosti s nejbližšími sousedy, ke stanovení vzdálenosti mezi dvěma objekty je nejčastěji používána euklidovská vzdálenost. V případě kvalitativní výstupní veličiny, algoritmus zjistí třídy všech  $k$  nejbližších sousedů a neznámý prvek přiřadí do třídy, která je v tomto výběru nejvíce zastoupena. Pokud je více tříd se stejným zastoupením, rozhodne o klasifikaci nejbližší sused, jehož výstupní hodnota patří do jedné z možných tříd. Máme-li kvantitativní výstupní veličinu, je výstupní hodnota nového objektu vypočtena jako průměr  $k$  nejbližších sousedů.

Další variantou je váhová metoda k-NN průměrů, u které platí, že čím je sused vzdálenější od nového objektu, tím má menší vliv na jeho konečnou výstupní hodnotu. Při použití váhové metody můžeme použít globální variantu, kdy dochází k výpočtu přes všechny trénovací záznamy, zatímco u metody bez váhy to není možné. Váhová metoda je odolná vůči šumu v trénovacích datech a při dostatku trénovacích dat je velmi efektivní. [21]

Klasifikátory i zde mohou být založeny na teorii klasických nebo fuzzy množin. Klasický k-NN klasifikátor přiřazuje neznámý objekt do příslušné třídy. Naopak fuzzy k-NN klasifikátor přiřazuje neznámému objektu příslušnost (nacházející se v intervalu  $\langle 0,1 \rangle$ ) v dané třídě. [15]

### 3.3.4 Diskriminační analýza

Diskriminační analýza je jednou z klasifikačních metod vícerozměrné statistické analýzy, pomocí které se objekt přiřadí do existující třídy. Klasifikační metody jsou neparametrické nebo parametrické. O neparametrických hovoříme v případě, pokud neznáme rozdělení náhodného vektoru charakterizující objekty. U parametrických metod má náhodný vektor konkrétní rozdělení (většinou normální rozdělení).

Při klasifikaci objektů se na základě výstupů konstruuje predikce založená na skupině znaků (vstupních datech). Jako nástroj jsou použita trénovací data, kde pro každý objekt je určen výstup ( $y$ ) a hodnoty znaků ( $x$ ). Na základě těchto dat je sestaven predikční model  $y = f(x)$  umožňující předpovědět výstup nového objektu. Jelikož se predikční model učí na základě trénovacích dat předvídat, jedná se o učení s učitelem. Nový objekt je zařazen do některé z existujících tříd na základě jeho znaků, kdy jsou porovnávány tyto znaky se znaky ostatních objektů. Objekt je zařazen do třídy na základě míry podobnosti, např. nejmenší Mahalanobisovy vzdálenosti.

Bez využití diskriminační analýzy by nové objekty byly zařazovány do tříd pouze pomocí apriorní pravděpodobnosti, nikoliv pomocí znaků objektu (diskriminátorů). Na základě  $p$  diskriminátorů  $x_1, x_2, \dots, x_p$  jsme tak schopni třídit nezařazené objekty do předem známých tříd. Každá třída je charakterizována funkcí hustoty pravděpodobnosti náhodné veličiny  $x$  označovanou jako  $f_j(x)$ . Diskriminační analýzu můžeme rozdělit na lineární a kvadratickou. O lineární diskriminační analýze (LDA) hovoříme v případě, kdy se hustoty  $f_j(x)$  jednotlivých tříd liší pouze středními hodnotami.

Pokud se navíc liší i kovariančními maticemi, jedná se o kvadratickou diskriminační analýzu (QDA). [22]

### 3.3.5 Rozhodovací stromy

V případě rozhodovacích stromů (RS) se jedná o hierarchický, nelineární systém umožňující uložení znalostí. Znalosti lze ze struktury RS extrahovat či použít k analýze nových dat. Existují algoritmy, které umí RS automaticky vytvářet. Následně lze z jejich struktury pomocí srozumitelných grafických výstupů interpretovat získané znalosti. Navíc je možné RS převádět do jazykových pravidel.


Před samotným vytvořením RS je nutné vhodně připravit data, která se mají analyzovat. Množina těchto dat (soubor záznamů) je složena z jednotlivých prvků (záznamů). Záznamem je myšlena 30s epocha a jeden konkrétní PSG signál představuje soubor záznamů. Záznam je tvořen vstupními atributy a jedním výstupním atributem. Atribut je vlastnost, jehož hodnota popisuje nebo charakterizuje sledovaný objekt. Daný záznam je tak tvořen hodnotami svých atributů. Atribut v našem případě představuje vypočtený příznak, kdy daná 30s epocha je tvořena hodnotami vybraných příznaků.

Při vytváření RS do každého uzlu vstupují trénovací data. Pokud jsou splněny ukončovací podmínky, dochází na základě nich ke konečné klasifikaci a z uzlu se stává list. V opačném případě je nutné stanovit takovou podmínku, na základě níž budou stávající data rozdělena do uzlů tak, aby byl dosažen co největší informační zisk.

Existuje několik druhů RS lišící se topologií, typem vstupních či výstupních proměnných. Jeden typ stromů navíc může být generován různými algoritmy. [21]

### 3.3.6 Metoda podpůrných vektorů

Algoritmy podpůrných vektorů (angl. Support Vector Machines, SVM) patří k metodám strojového učení, které jsou schopny oddělit nelineárně ohraničená data pomocí lineární funkce. Základním principem je převod dvourozměrného původního prostoru do vícedimenzionálního, ve které jsme již schopni oddělit jednotlivé třídy lineárně. Hledáme nadrovinu, která v prostoru příznaků optimálně rozděluje trénovací data. Data ležící této nadrovině nejbližše se nazývají podpůrné vektory. [23][24]



Obr. 6 Transformace lineárně neseparabilních dat do prostoru o vyšší dimenzi, kde jsou data již lineárně separabilní [24]

V tab. 2 je znázorněno srovnání některých klasifikátorů a vybraných příznaků od vybraných autorů, kteří pro výpočet parametrů použili EEG, EMG a EOG signály, stejně jako v této práci.

Tab. 2 Srovnání různých metod klasifikace a vybraných příznaků u různých autorů


Autor	Příznaky	Klasifikátor	Klasifikované fáze	Úspěšnost
Agarwal et al. [25]	Amplituda signálu, dominantní rytmus, frekvenčně váhovaná energie, detekce spánkových vřeten, alfa a theta pomalo-vlnný index, přítomnost očních pohybů	Shluková analýza	W, REM, S1-S4	76,8 %
Pacheco [27]	Výkon v delta, alfa a sigma pásmu, aktivita K-komplexu, kombinovaná Hjorthova aktivita a mobilita, relativní výkon theta a alfa	Vícevrstvý perceptron: 7-10-4 + pravidla	W, REM, S1-S4	90 %
Schwaibold [28]	Spektrální výkonová hustota, korelační koeficient, detekce K-komplexů, spánkových vřeten a vertexových vln	Vícevrstvý perceptron + neuro-fuzzy systém	W, REM, S1-S4	70,7 % (u nemocných subjektů), 79,8 % (u zdravých)
Alvarez-Estevez [29]	Průměrné a maximální hodnoty EMG a EOG, detekce K-komplexů a spánkových vřeten, EEG: relativní výkon alfa, beta, delta, theta (FFT)	Fuzzy logika (111 fuzzy pravidel)	W, N1-N3, REM	84 %
Liang [30]	EEG, EMG, EOG: celkový výkon, relativní výkon delta, alfa a spánkových vřeten, spektrální frekvence	Rozhodovací stromy (DTL)	W, N1-N3, REM	86,68 %
Zoubek [12]	Koeficient šikmosti a špičatosti, 75. percentil, směrodatná odchylka, entropie (EEG, EMG, EOG), EEG: relativní výkon alfa, beta, delta, theta, sigma (FFT), EMG: relativní výkon pásma 12,5-32 Hz, EEG: relativní RMS vlnkových koeficientů v 5 frekvenčních pásmech	Vícevrstvá neuronová síť se zpětným šířením chyby (BP MLNN): 5-6-5 a 10-6-5	W, S1-S4, REM	80% (EEG, EMG, EOG), 84,75 % W, 64,56 % S1, 85,55 % S2, 92,9 % S3-S4, 72,81 % REM
Tang [31]	Vlnková transformace, autoregresivní model, Hilbert-Huangova transformace	Metoda podpůrných vektorů (SVM)	W, S1-S4, REM	77,9%
Oropesa [32]	EEG: RMS vlnkových koeficientů v pásmech: K-komplexy + delta (0,4-1,55 Hz), delta (1,55-3,2 Hz), theta (3,2-8,6 Hz), alfa (8,6-11,0 Hz), spánková vřetena (11,0-15,6 Hz), beta1 (15,6-22,0 Hz), beta2 (22 – 37,5 Hz), celkový výkon, relativní výkon delta (0,4 – 3,2 Hz), relativní výkon alfa, relativní výkon k-komplexů + spánková vřetena, alfa/theta, delta (0,4-3,2)/theta	Vícevrstvá neuronová síť se zpětným šířením chyby (BP MLNN): 13-10-6	W, REM, S1-S4	77,6 %

## 4 ANALÝZA PSG SIGNÁLŮ ZE STUDIE RELIEF

PSG signály použité v této práci pochází ze studie RELIEF, která se zabývala léčbou pacientů s farmakorezistentní hypertenzí pomocí metody ablace renálního sympatiku. Studie vznikla ve spánkové laboratoři Fakultní nemocnice u sv. Anny v Brně a obsahuje záznamy přibližně 30 pacientů, z nichž bylo náhodně vybráno 6 záznamů (záznam 40, 42, 43, 44, 48 a 51). V rámci této studie bylo nejdříve provedeno polysomnografické vyšetření noc před zákrokem a po šesti měsících po zákroku následovalo druhé, kontrolní vyšetření. Právě z kontrolního vyšetření byly použity vybrané záznamy.

### 4.1 Analyzovaná data

Z PSG signálů, které byly během vyšetření zaznamenány, byl vybrán 1 kanál EEG C4-M1, viz obr. 7. Dále 1 kanál EOG (pro levé oko) a 1 kanál EMG (pro pohyb brady). Místo pro oční elektrodu je určeno přímkou vedenou z elektrody Fpz přes střed oka a umístěné ve vzdálenosti asi 1 cm od okraje oka (1 cm směrem dozadu k uchu a 1 cm kolmo dolů). Bradové elektrody Chin1 a Chin2 jsou umístěny pod bradou a vedle sebe. Umístění elektrod pro snímání EOG a EMG je zobrazeno na obr. 8. Všechny signály byly snímány se vzorkovací frekvencí 256 Hz.



Obr. 7 Rozmístění elektrod při snímání EEG signálu v rámci studie RELIEF



Obr. 8 Umístění elektrod při snímání EOG (vlevo) a EMG signálu (vpravo)

Součástí každého záznamu je hypnogram, který vznikl na základě hodnocení signálů lékařem dle AASM standardu po epochách dlouhých 30 s. Jednotlivé spánkové fáze jsou v hypnogramu značeny následovně: W – 0, N1 fáze – 1, N2 fáze – 2, N3 fáze – 3, REM fáze – 5, neskórovaná fáze – 9. Na základě hypnogramů byly vybrány signály rozděleny do jednotlivých spánkových fází, z nichž byly dále extrahovány vybrané příznaky.

## 4.2 Metody statistické analýzy

Příznaky rozumíme určité charakteristiky signálu, které popisují daný signál. Hodnoty některých příznaků jsou charakteristické pro jednotlivé spánkové fáze. Pro odlišení spánkových fází nestačí nalezení jednoho příznaku, je nutné nalézt množinu příznaků, pomocí které jsme již schopni jednotlivé spánkové fáze správně klasifikovat.

Pomocí statistické analýzy budeme vybírat takové příznaky, které přinášejí odpovídající míru informace. Vybraný příznak nabývá rozdílných hodnot u jednotlivých spánkových fází.

### Analýza rozptylu

Základní statistickou metodou, která umožňuje zjistit, zdali mezi dvěma nebo více skupinami jsou významné rozdíly, je tzv. analýza rozptylu (ANOVA, analysis of variance). Tato metoda srovnává rozptyl hodnot mezi výběry s rozptylem hodnot uvnitř výběrových souborů. Naším cílem je, aby rozptyl hodnot uvnitř klasifikačních tříd byl co nejmenší a současně mezi třídami byl co největší. Aby analýza rozptylu byla platná, musí být splněny následující předpoklady: nezávislost pozorovaných hodnot, normalita hodnot jednotlivých náhodných výběrů a stejný rozptyl hodnot ve všech srovnávaných skupinách. K rozhodnutí, zda pozorované hodnoty pochází z normálního rozdělení pravděpodobnosti, byl použit Lillieforsův test, který je určen pro hodnocení shody výběrového rozdělení s normálním. K jeho výpočtu byla využita implementovaná funkce Matlabu *lillietest*.

Jelikož předpoklady analýzy rozptylu nejsou splněny, byl použit Kruskal-Wallisův test, což je nejpoužívanější neparametrická alternativa k analýze rozptylu.

Kruskal-Wallisův test nevyžaduje předpoklad normality pozorovaných hodnot. Na druhou stranu neparametrický test má menší sílu, což je nutné kompenzovat větší velikostí vzorku. Kruskal-Wallisův test je založen na pořadí pozorovaných hodnot, kdy nejdříve hodnoty uspořádáme podle velikosti (jakoby pocházely z jednoho výběru) a následně jim přiřadíme pořadí.

Nulová hypotéza  $H_0$  tohoto testu předpokládá u skupin shodnost mediánu, naopak u alternativní hypotézy  $H_1$  alespoň jedna dvojice mediánů se nerovná. Je-li nulová hypotéza platná či nikoliv určíme pomocí p-hodnoty, kterou definujeme jako nejmenší hladinu významnosti testu  $\alpha$  (obvykle  $\alpha = 0,05$ ), při které zamítáme nulovou hypotézu. Pokud nám při hodnocení statistického testu vyjde p-hodnota menší než  $\alpha$ , nulovou hypotézu zamítneme a budeme hovořit o statisticky významném výsledku na dané hladině významnosti  $\alpha$ . Pokud je p-hodnota větší než  $\alpha$ , nulovou hypotézu nezamítáme, platí  $H_0$ . V této práci byla pro výpočet Kruskal-Wallisova testu použita funkce *kruskalwallis* implementovaná v Matlabu. [33]

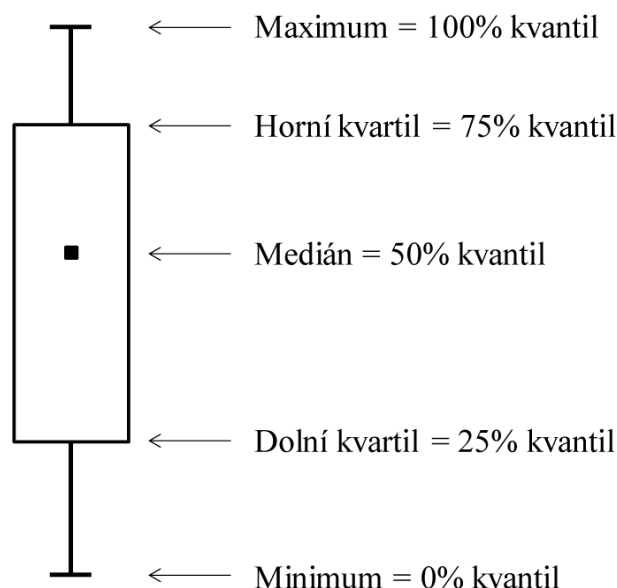
Druhým krokem při analýze rozptylu je post-hoc analýza neboli mnohonásobné porovnávání, která spočívá v porovnání aritmetických průměrů všech dvojic spánkových fází. Pokud dojde u Kruskal-Wallisova testu k zamítnutí nulové hypotézy, tímto způsobem zjišťujeme, mezi kterými dvojicemi spánkových fází je statisticky významný rozdíl. V práci byl použit Tukey test, který byl vypočítán pomocí funkce Matlabu *multcompare*. Tento post-hoc test pomocí kombinační tabulky zobrazuje hladiny statistické významnosti  $p$  mezi všemi aritmetickými průměry srovnávaných dvojic. [26]

### **Krabicové grafy**

Příznaky si můžeme graficky znázornit pomocí krabicových grafů neboli boxplotů. Krabicové grafy se navíc dají použít k ověření předpokladu o shodnosti rozptylu hodnot ve všech srovnávaných skupinách u výše zmíněné metody analýzy rozptylu.

Graf se skládá z obdélníku, který je rozdělen na dvě části, dělicí čára odpovídá mediánu (prostřední pozorované hodnotě) a jeho hrany tvoří dolní a horní kvartil (25% a 75% kvantil). Celý obdélník pokrývá 50 % pozorovaných hodnot. V grafu se pomocí tzv. fousků (whiskers), které dosahují za hranice obdélníku, vyznačují polohy hodnot více vzdálených od mediánu. Nejčastěji odpovídají 5% kvantilu (spodní fousek) a 95% kvantilu (horní fousek). Odlehlé hodnoty jsou zobrazeny jako jednotlivé body. Na obr. 9 je zobrazen krabicový graf s vyznačenými významnými kvantily. [33] Pro vykreslení těchto grafů byla využita funkce Matlabu *boxplot*.





Obr. 9 Krabicový graf s vyznačením vybraných kvantilů [33]

### 4.3 Vybrané příznaky v časové oblasti


Pro analýzu PSG signálů byly v časové oblasti vybrány parametry: střední hodnota, směrodatná odchylka, koeficient šikmosti, koeficient špičatosti, entropie, 75. percentil a Hjorthovy deskriptory (aktivita, mobilita, složitost). Každý parametr byl počítán zvlášť pro jednotlivé spánkové fáze N1, N2, N3, REM a pro bdělost W, navíc z jednotlivých 30s epoch. Vybrané parametry byly aplikovány na EEG kanál C4-M1, EOG kanál E1 a na EMG kanál šesti náhodně vybraných signálů. V tab. 3 lze vidět 6 signálů, které byly pro analýzu použity, a celkový počet epoch v jednotlivých spánkových fázích.

Tab. 3 Celkový počet 30s epoch jednotlivých fází

Signál	W	N1	N2	N3	REM
Signál 40	56	67	275	133	188
Signál 42	248	105	413	90	27
Signál 43	290	42	317	117	44
Signál 44	93	360	55	22	55
Signál 48	76	215	137	139	77
Signál 51	69	69	420	182	207
<b>Celkem</b>	<b>832</b>	<b>858</b>	<b>1617</b>	<b>683</b>	<b>598</b>

Na základě statistické analýzy pomocí Kruskal-Wallisova testu bylo zjištěno, že střední hodnota počítána u EEG i EOG signálů není vhodný parametr pro následnou klasifikaci jednotlivých spánkových fází. Je to vidět i z obr. 10, kde dochází u jednotlivých spánkových fází k překrytí daných kvantilů. Tento parametr je statisticky nevýznamný, jelikož při jeho výpočtu nedochází k zamítnutí nulové hypotézy na hladině významnosti 0,05.

Naopak u směrodatné odchylky, koeficientu šikmosti a špičatosti, entropie, 75. percentilu a Hjorthových deskriptorů všech tří zmíněných PSG signálů a u střední hodnoty EMG signálu je nulová hypotéza na hladině významnosti zamítnuta. Je přijata alternativní hypotéza, podle které se alespoň jedna dvojice mediánů u jednotlivých spánkových fází liší. Tyto parametry jsou podle Kruskal-Wallisova testu na hladině významnosti 0,05 statisticky významné.



Obr. 10 Krabicové grafy pro střední hodnotu jednotlivých spánkových fází 6 signálů, EOG kanál E1,  $p > 0,05$

Jelikož pomocí Kruskal-Wallisova testu jsme získali mnoho parametrů, které byly označeny jako vhodné pro následnou automatickou klasifikaci, byla navíc provedena selekce příznaků pomocí dopředného selekčního algoritmu.

### Dopředný selekční algoritmus

Dopředný selekční algoritmus začíná s prázdnou množinou. V dalším kroku se do ní vloží parametr s nejlepší hodnotou selekční kritériální funkce. V následujících krocích se přidává ten parametr, který dosahuje s již vybranými příznaky nejlepší hodnoty kritéria, což se dá vyjádřit jako [12]:

$$J(Y_{k+1}) = \max_{x_j} J(Y_k \cup x_j), x_j \in (X - Y_k),$$

kde  $J$  je kritériální funkce,  $Y_k$  je soubor vybraných příznaků v  $k$ . kroku,  $X$  je množina všech příznaků,  $x_j$  je  $j$ . příznak z množiny zbývajících, nevybraných příznaků  $X - Y_k$ .

V algoritmu sekvenční dopředné selekce byla použita funkce *sequentialfs*, která je součástí statistického toolboxu v Matlabu. Funkce prokládá data multinomiálním logistickým modelem, který popisuje vztahy mezi závislou (vysvětlovanou) proměnnou a skupinou nezávislých (vysvětlujících) proměnných. Jelikož vysvětlovaná proměnná není spojitá, využíváme logistickou regresi.

Logistická regrese je jednou z variant zobecněného lineárního modelu, v práci je využita (multi)nomiální logistická regrese, kde nomiální závislá proměnná nabývá 5 stavů (W, N1, N2, N3 a REM), a skupina nezávislých proměnných je tvořena 25 příznaky. Jedná se o příznaky v časové oblasti, které byly Kruskal-Wallisovým testem vyhodnoceny jako statisticky významné.

Multinomiální logistická regrese je počítána pomocí funkce *mnrfit*, kterou funkce *sequentialfs* volá pomocí funkčního handlu. Funkce *mnrfit*, sloužící pro výpočet kritéria pro zařazení příznaků do modelu, vrací odchylky proložení neboli deviance, které jsou počítány metodou maximální věrohodnosti (angl. maximum likelihood).


U funkce *sequentialfs* byla pro výpočet dopředné selekce nastavena maximální hodnota kritéria, při které již dochází k ukončení algoritmu sloužícího pro výběr vhodných příznaků. Kritérium je vypočteno pomocí funkce *chi2inv*, jejíž vstupními parametry je kritická hodnota chí kvadrát rozdělení při zvolené hladině významnosti  $\alpha$  a stupně volnosti. Pravděpodobnost je nastavena na hodnotu 0,95 ( $1 - \alpha$ ) a stupeň volnosti na hodnotu 4, což odpovídá počtu stavů závislé proměnné  $k - 1$ . Výstupem funkce *sequentialfs* je vektor s vybranými příznaky. [36][37] Pomocí dopředné selekce jsme získali příznaky, které jsou uvedeny v tab. 4.

Tab. 4 Skupina statisticky významných příznaků získaných pomocí dopředné selekce


PSG signál	Vybrané příznaky
EEG signál	Aktivita, entropie, mobilita, složitost.
EMG signál	Mobilita, entropie, koeficient šikmosti, střední hodnota.
EOG signál	Směrodatná odchylka, koeficient šikmosti.

Na obr. 11 – obr. 13 je zobrazena ukázka vybraných příznaků v časové oblasti, které podle Kruskal-Wallisova testu vykazují na hladině významnosti 0,05 statisticky významné výsledky a zároveň jsou tyto příznaky výsledkem dopředné selekce. Z krabicových grafů pro směrodatnou odchylku jednotlivých spánkových fází a počítaných pro EOG signály lze vyčíst, že hodnota mediánu W fáze se od ostatních fází liší. I když hodnota dolního kvartilu W fáze se překrývá s hodnotou horního kvartilu N3 a REM fáze, byl tento parametr zvolen za vhodný pro následnou automatickou klasifikaci. Avšak výsledek může být touto skutečností, a také kvůli překryvu s maximálními hodnotami ostatních fází, negativně ovlivněn.

Na obr. 12, kde jsou znázorněny krabicové grafy pro entropii jednotlivých spánkových fází a pro EMG signály, vidíme, že REM fáze se odlišuje od zbývajících svým mediánem a dolním a horním kvantilem. I přes překryv jeho maximálních a minimálních hodnot s ostatními fázemi, je tento parametr použit při následné klasifikaci.




Obr. 11 Krabicové grafy pro směrodatnou odchylku jednotlivých spánkových fází a u EOG signálů



Obr. 12 Krabicové grafy pro entropii jednotlivých spánkových fází a u EMG signálů

Na obr. 13. jsou zobrazeny krabicové grafy pro mobilitu jednotlivých spánkových fází vypočtených u EEG signálů. Lze si všimnout, že fáze N3 se liší mediánem a svými kvartily od ostatních. Tento parametr i přes překrytí maximálních a minimálních hodnot s ostatními fázemi použijeme při následné klasifikaci.



Obr. 13 Krabicové grafy pro mobilitu jednotlivých spánkových fází a u EEG signálů


#### 4.4 Vybrané příznaky ve frekvenční oblasti

Analýza ve frekvenční oblasti byla provedena u šesti náhodně vybraných EEG a EMG signálů (u stejných jako v předchozím případě). Při frekvenční analýze získáváme spektrální výkonovou hustotu EEG i EMG signálu. Pro určení spektrální výkonové hustoty byla použita neparametrická metoda, konkrétně metoda Welchova periodogramu.

U této metody je každá 30s epocha, což odpovídá 7680 vzorkům, rozdělena pomocí okna na kratší segmenty. V našem případě bylo zvoleno 3s okno, které odpovídá 768 vzorkům. Pro dosažení lepšího časového a frekvenčního rozlišení bylo zvoleno 50% překrytí sousedních oken. Kvůli potlačení jevu prosakování spekter je každý segment vynásoben váhovacím Hammingovým oknem. Z těchto jednotlivých segmentů se již provádí výpočet periodogramu, kdy z každého úseku je pomocí FFT vypočteno spektrum. Zprůměrováním dílčích periodogramů získáváme výslednou spektrální výkonovou hustotu.

U EEG signálů hodnotíme výkonové spektrum podle zastoupení frekvenčních složek v jednotlivých frekvenčních pásmech, která jsou rozdělena na pásma delta (0 – 4 Hz), theta (4 – 8 Hz), alfa (8 – 13 Hz), beta1 (13 – 22 Hz) a beta2 (22 – 35 Hz), což je

znázorněno na obr. 14. Vybranými parametry ve frekvenční oblasti pro EEG signály je výkonová spektrální hustota delta, theta, alfa, beta1 a beta2 pásma, respektive jejich relativní výkonová hustota  $\delta_{REL}$ ,  $\theta_{REL}$ ,  $\alpha_{REL}$ ,  $\beta1_{REL}$ ,  $\beta2_{REL}$ .




Obr. 14 Ukázka výpočtu výkonového spektra z jedné epochy EEG signálu (s vyznačením pěti frekvenčních pásem)

U EMG signálů byla počítána relativní výkonová hustota  $P_{rel}(EMG, high)$  ve frekvenčním pásmu 12,5 – 32 Hz a to na základě vztahu [12]:

$$P_{rel}(EMG, high) = \frac{EMG, [12,5 - 32 \text{ Hz}]}{EMG, [8 - 32 \text{ Hz}]} \quad (18)$$

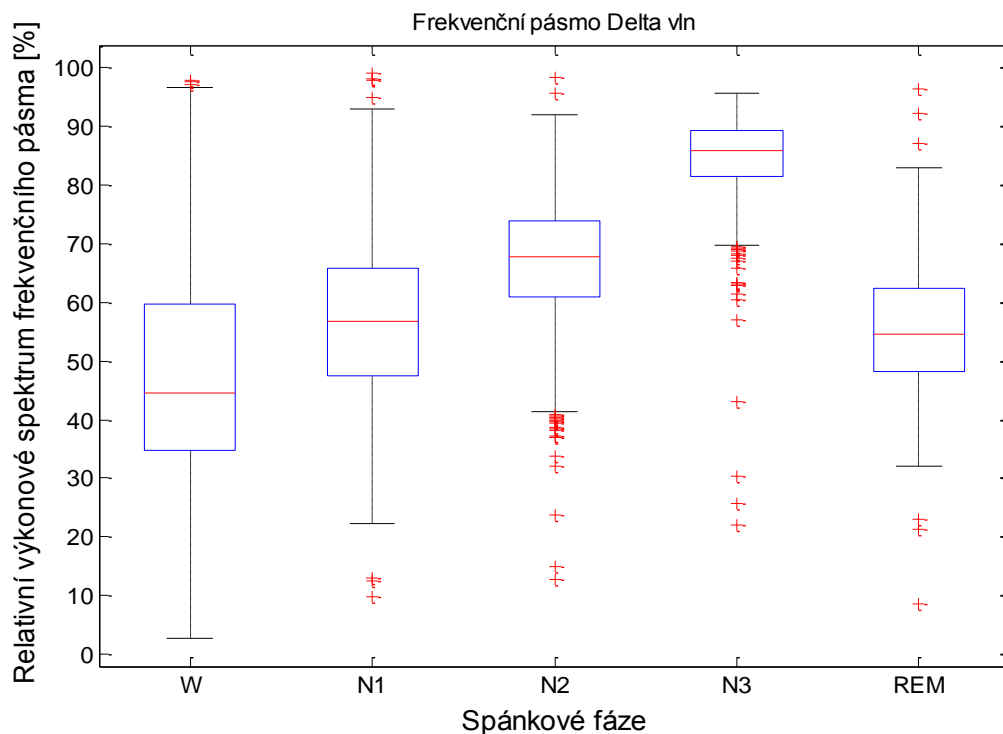
Ve frekvenční oblasti bylo vybráno celkem 6 parametrů:  $\delta_{REL}$ ,  $\theta_{REL}$ ,  $\alpha_{REL}$ ,  $\beta1_{REL}$ ,  $\beta2_{REL}$  počítaných z EEG signálů a  $P_{rel}(EMG, high)$  počítána z EMG signálů. Získané parametry jsou opět počítány pro jednotlivé spánkové fáze a pro EEG kanál C4-M1 a EMG kanál šesti signálů. Na základě Kruskal-Wallisova testu dochází u všech šesti parametrů k zamítnutí nulové hypotézy na hladině významnosti 0,05. U všech zmíněných parametrů se tak jedná o statisticky významný výsledek. Dále byla na tyto parametry aplikována selekce příznaků pomocí dopředného selekčního algoritmu, na jehož základě jsme získali statisticky významné příznaky:  $\delta_{REL}$ ,  $\theta_{REL}$ ,  $\beta1_{REL}$ ,  $\beta2_{REL}$  a  $P_{rel}(EMG, high)$ . Parametr  $\alpha_{REL}$  nebyl vybrán.

Na obr. 15 jsou zobrazeny krabicové grafy pro relativní výkonovou hustotu  $P_{rel}(EMG, high)$  jednotlivých spánkových fází. W fáze se od zbylých fází odlišuje, avšak horní kvartil N1 a N2 fáze přesahuje hodnotu dolního kvartilu W fáze. I přes tuto skutečnost a také překrytí maximálních a minimálních hodnot u ostatních spánkových fází byl tento příznak vybrán k následné klasifikaci.



Obr. 15 Krabicové grafy pro relativní výkonovou hustotu  $P_{rel}(EMG, high)$  jednotlivých spánkových fází a u EMG signálů

Na obr. 16 zobrazující krabicové grafy pro relativní výkonové spektrum delta pásma u jednotlivých spánkových fází vidíme, že nejvyšší hodnotu mediánu má N3 fáze. Ta se od ostatních fází odlišuje i dolním a horním kvartilem. Tento příznak použijeme pro automatickou klasifikaci, i když maximální hodnoty zbývajících fází mohou výsledek výrazně ovlivnit.



Obr. 16 Krabicové grafy pro relativní výkonové spektrum delta pásma jednotlivých spánkových fázích a u EEG signálů

#### 4.5 Vybrané příznaky v časově-frekvenční oblasti

U EEG signálů byla navíc provedena analýza v časově-frekvenční oblasti, konkrétně pomocí diskretní vlnkové transformace, jejíž základní princip byl popsán v kapitole 3.2.3. Jedná se o dekompozici signálu, kdy EEG signál se vzorkovací frekvencí 256 Hz rozkládáme do pěti frekvenčních pásem: delta (0 - 4 Hz), theta (4 - 8 Hz), alfa (8 - 16 Hz), beta (16 - 32 Hz) a gamma (32 - 64 Hz), jak je uvedeno v tab. 5 [34].

Tab. 5 Dekompozice EEG signálu do jednotlivých frekvenčních pásem

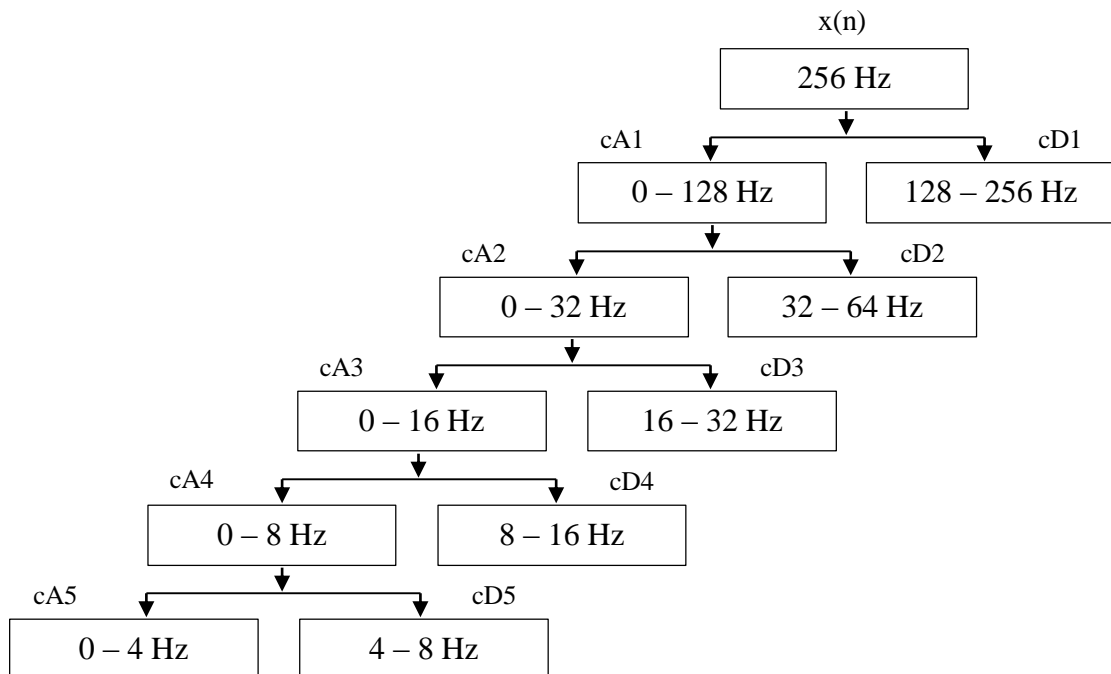
Frekvenční rozsah [Hz]	Frekvenční pásmo	Dekompoziční stupeň	Šířka frekvenčního pásma [Hz]
0 – 4	Delta	CA5	4
4 – 8	Theta	CD5	4
8 – 16	Alpha	CD4	8
16 – 32	Beta	CD3	16
32 – 64	Gamma	CD2	32
64 – 128	Šum	CD1	64

Dekompozici signálu provádíme pomocí dvojice kvadraturních filtrů, z nichž jeden je typu dolní propust (DP) a druhý typu horní propust (HP). Vstupní signál filtrujeme dolní propustí, čímž získáme aproximační koeficienty obsahující



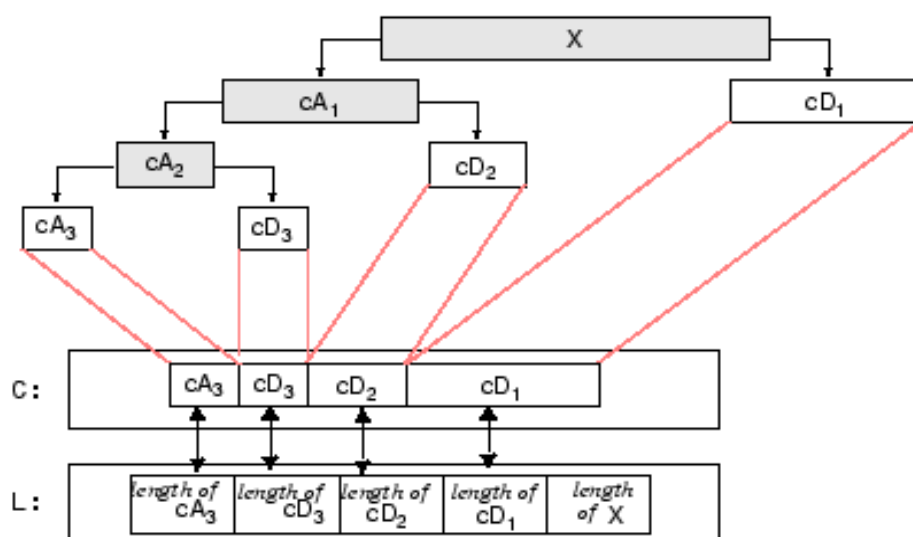
nízkofrekvenční informace  $cA1$ , a pomocí horní propusti, kdy obdržíme koeficienty detailů obsahující vysokofrekvenční informace  $cD1$ . Výstupy obou filtrů jsou podvzorkovány na polovinu vstupních vzorků. V druhé úrovni rozkladu koeficienty aproximace filtrujeme shodným rozkladem filtrů jako v předchozím kroku. Tím získáváme další soubor aproximačních  $cA2$  a detailních  $cD2$  koeficientů. Po druhém stupni dekompozice následují další tři dekompozice, jak je naznačeno na obr. 17. [17]

$cA1$ ,  $cA2$ ,  $cA3$ ,  $cA4$  a  $cA5$  značí aproximace koeficientů a  $cD1$ ,  $cD2$ ,  $cD3$ ,  $cD4$  a  $cD5$  koeficienty detailů získaných pomocí postupné dekompozice. Použitím pěti úrovní rozkladu získáváme pět EEG frekvenčních pásem. Pro výběr vlnky byla použita dostupná literatura, nejčastěji používanou vlnkou je vlnka Daubechies, právě proto byla vybrána vlnka Daubechies db3 vycházející z [12], která byla aplikována na jednotlivé 30s epochy signálu.



Obr. 17 Dekompozice EEG signálu se vzorkovací frekvencí 256 Hz [34]

Po zvolení vlnky db3 a stupni rozkladu 5 byla provedena dekompozice každé epochy pomocí matlabovské funkce *wavedec*. Výstupem funkce jsou aproximační a detailní koeficienty uložené do proměnné  $C$  a v proměnné  $L$  je definováno, která část proměnné  $C$  představuje aproximační koeficienty zvolené úrovně rozkladu  $N$  a které části představují koeficienty detailů úrovně 1 až  $N$ . Na obr. 18 je znázorněn výstup třístupňové vlnkové dekompozice.



Obr. 18 Výstupní proměnné třístupňové vlnkové dekompozice pomocí funkce *wavedec* [35]

Následuje funkce, implementována v Matlabu, *wrcoef*, která na základě vlnkové dekompoziční struktury (proměnné *C* a *L*) a zvolené vlnky rekonstruuje koeficienty jednorozměrného signálu [35]. Zde je znázorněna rekonstrukce *cD4* koeficientů představující alfa frekvenční pásmo:

```
D4 = wrcoef('d',C,L,waveletFunction,4); %Alfa
```

Následujícím krokem je samotný výpočet parametrů, které byly počítány z vlnkových koeficientů generovaných DWT pomocí pětistupňové vlnkové dekompozice. Pro každou 30s epochu šesti EEG signálů a pro jednotlivé spánkové fáze byl počítán dle vzorce (19) výkon vlnkových koeficientů v 5 frekvenčních pásmech. Tím jsme získali 5 parametrů: výkon v delta, theta, alfa, beta a gamma pásmu (frekvenční rozsah jednotlivých pásem byl znázorněn v tab. 5).

$$vykon = \frac{1}{n} \sum_{i=1}^n x_i^2, \quad (19)$$

kde  $n$  je délka epochy a  $x$  jsou hodnoty signálu.

Dalšími dvěma parametry jsou poměry výkonů, prvním z nich je poměr výkonu v alfa pásmu a výkonu v theta pásmu. Druhým je poměr výkonu v delta pásmu a výkonu v theta pásmu. Dalšími třemi parametry jsou relativní hodnoty výkonu v delta, theta a alfa pásmu, které jsou počítány jako poměr výkonu ve vybraném frekvenčním pásmu a celkovou hodnotou výkonu, přičemž celkový výkon je dán součtem dílčích výkonů uvedených pěti pásem. Všechny tyto parametry stejně jako předchozí parametry v časové a časově-frekvenční oblasti byly vybrány na základě studia literatury. Na základě

literatury byla spočtena i relativní entropie v pěti frekvenčních pásmech, tento vzorec jsem upravila a získala tak dalších pět parametrů, které byly získány pomocí entropie vlnkových koeficientů v jednotlivých frekvenčních pásmech podělené celkovým výkonem dané epochy. Jelikož lépe vycházela moje upravená varianta, v další části práce byly použity právě tyto parametry. V časově-frekvenční oblasti jsme tak získali 15 parametrů souhrnně uvedených v tab. 6:

Tab. 6 Parametry v časově-frekvenční oblasti

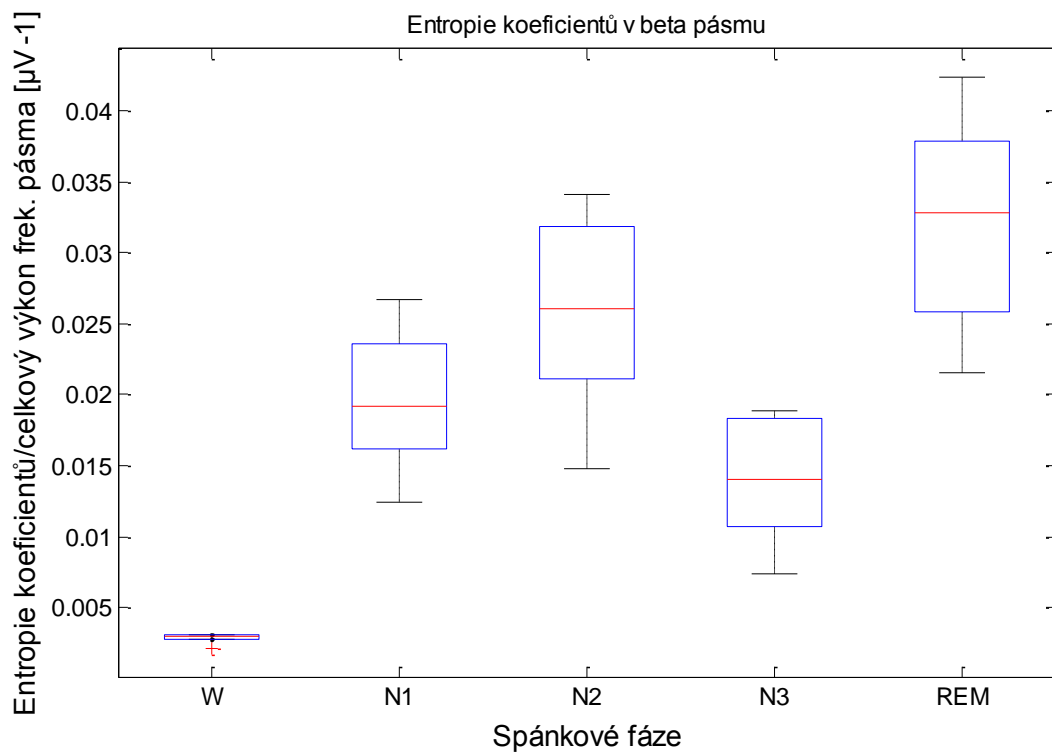
Charakter parametru	Parametry
výkon	vykonD, vykonT, vykonA, vykonB, vykonG
poměr výkonů	vykonAT = $vykonA/vykonT$ , vykonDT = $vykonD/vykonT$
relativní výkon	vykonD <sub>rel</sub> = $vykonD/celkovyVykon$ , vykonT <sub>rel</sub> = $vykonT/celkovyVykon$ , vykonA <sub>rel</sub> = $vykonA/celkovyVykon$
entropie/celkový výkon	entD = $entropyD/celkovyVykon$ , entT = $entropyT/celkovyVykon$ , entA = $entropyA/celkovyVykon$ entB = $entropyB/celkovyVykon$ , entG = $entropyG/celkovyVykon$ .

Celkový výkon *celkovyVykon* byl vypočítán dle následujícího vzorce:


$$celkovyVykon = vykonD + vykonT + vykonA + vykonB + vykonG. \quad (20)$$

Na vybrané parametry byl aplikován Kruskal-Wallisův test, který u všech parametrů prokázal statisticky významný výsledek na hladině významnosti 0,05. Následně na základě dopředného selekčního algoritmu byly vybrány parametry: vykonDT, vykonD<sub>rel</sub>, vykonT<sub>rel</sub>, vykonA<sub>rel</sub>, entT, entA, entB a entG. U všech těchto 8 parametrů byl prokázán statisticky významný výsledek.

Krabicové grafy pro parametry entB a entG, které byly označeny za statisticky významné, jsou zobrazeny na obr. 19 a obr. 20. Krabicové grafy pro zbylé parametry jsou zobrazeny v kapitole 11. Z obr. 19 vidíme, že fáze W se zřetelně odlišuje od zbylých fází, naopak z obr. 20 pro entropii koeficientů v gamma pásmu pro jednotlivé spánkové fáze lze vyčíst, že fáze REM se liší od ostatních fází, nedochází zde k překryvu hodnot.



Obr. 19 Krabicové grafy pro entropii koeficientů beta pásma/celkový výkon jednotlivých spánkových fází a u EEG signálů



Obr. 20 Krabicové grafy pro entropii koeficientů gamma pásma/celkový výkon jednotlivých spánkových fází a u EEG signálů

## 4.6 Výsledné vybrané příznaky

Z analýzy v časové, frekvenční a časově-frekvenční oblasti jsme celkově získali 23 parametrů: 10 z časové oblasti, 5 z frekvenční oblasti a 8 z časově-frekvenční oblasti. Avšak zároveň na všechny parametry jsme znova aplikovali dopředný selekční algoritmus. Výsledkem je 20 vybraných příznaků zobrazených v tab. 7.

Tab. 7 Výsledné vybrané příznaky

Analýza	Vybrané parametry
časové oblasti	EOG: směrodatná odchylka
	EMG: mobilita, entropie, koeficient šikmosti, střední hodnota
	EEG: mobilita, entropie
frekvenční oblasti	EMG: $P_{rel}(EMG, high)$
	EEG: $\delta_{REL}, \theta_{REL}, \beta_{1REL}, \beta_{2REL}$
časově-frekvenční oblasti	EEG: $vykonDT, vykonD_{rel}, vykonT_{rel}, vykonA_{rel}, entT, entA, entB, entG$

V Příloze A jsou pomocí krabicových grafů zobrazeny výsledné vybrané příznaky s výjimkou těch, které již byly znázorněny a popsány výše. Jak již bylo řečeno, každý parametr byl počítán pro jednotlivé spánkové fáze a celkově pro 4 588 třicetisekundových epoch šesti náhodně vybraných signálů – příslušného PSG kanálu. U EEG signálů byl vybrán kanál C4-M1 a u EOG kanál E1.

Na vybrané příznaky byl aplikován výše zmíněný Tukey test, pomocí něhož se dá zjistit, mezi konkrétně kterými dvojicemi spánkových fází je statisticky významný rozdíl. V tab. 8 jsou v posledním sloupci u vybraných parametrů znázorněny dvojice spánkových fází, mezi kterými není rozdíl statisticky významný. Tyto spánkové fáze nelze mezi sebou odlišit. V prostředním sloupci jsou zobrazeny spánkové fáze parametrů, jejichž hodnoty se zároveň liší pro všechny fáze, jsou statisticky významné od zbývajících fází (na hladině významnosti 0,05). Například u mobility počítané u šesti EMG signálů lze od zbývajících fází odlišit W, N1 a také N2 fázi. U modře zvýrazněných parametrů by se podle Tukey testu měli dát od sebe odlišit všechny spánkové fáze, mezi všemi fázemi je statisticky významný rozdíl.

Tab. 8 Spánkové fáze vybraných příznaků vhodné pro automatickou klasifikaci


Vybraný příznak		Fáze statisticky významné od zbývajících fází	Statisticky nevýznamné dvojice fází	
časová oblast	EOG:	směrodatná odchylka	W, N1, N2, N3, REM	-
	EMG:	mobilita	W, N1, N2	N3-REM
		entropie	W, N1, N2, N3, REM	-
		koeficient šikmosti	W	N1-REM, N2-N3
		střední hodnota	N2	W-N1, N3-REM
	EEG:	mobilita	W, N1, N2, N3, REM	-
		entropie	N1, N3, REM	W-N2
frekvenční oblast	EMG:	$P_{rel}(EMG, high)$	W, N3, REM	N1-N2
	EEG:	$\delta_{REL}$	W, N1, N2, N3, REM	-
		$\theta_{REL}$	N3, REM	W-N1, W-N2, N1-N2
		$\beta_{1REL}$	W, N2, N3	N1-REM
		$\beta_{2REL}$	W, N2, N3	N1-REM
časově-frekvenční oblast	EEG:	vykonDT	W, N1, N2, N3, REM	-
		vykonD <sub>rel</sub>	W, N2, N3	N1-REM
		vykonT <sub>rel</sub>	N3, REM	W-N2, N1-N2
		vykonA <sub>rel</sub>	N2, N3	W-REM, N1-REM
		entT	W, N1, N2, N3, REM	-
		entA	N1, N3, REM	W-N2
		entB	W, N1, N2, N3, REM	-
		entG	W, N1, N2, N3, REM	-

## 5 KLASIFIKACE PSG SIGNÁLŮ

Jak ukázalo studium literatury, velmi často používanou metodou klasifikace je vícevrstvá neuronová síť s učícím algoritmem zpětného šíření chyby, což je patrné i z tab. 2, proto tento model neuronové sítě v této práci použijeme. Mezi další vybrané klasifikační metody patří k-nearest neighbours a diskriminační analýza. Všechny tyto klasifikátory byly vytvořeny v programovém prostředí Matlab verze 2011a. Klasifikace byla provedena na 6 signálech, na stejných jako v případě výpočtu klasifikačních příznaků. V prvním případě dochází k učení na pěti z nich a na šestém k samotné klasifikaci. Jedná se o tzv. 6-násobnou křížovou validaci, kdy datový soubor je rozdělen na 6 částí, přičemž jedna část je vždy použita na testování a zbylých 5 částí je využito na trénování [24]. Ve druhém případě je část z 6 signálů vybrána k učení a část ke klasifikaci. U všech klasifikátorů došlo ke klasifikaci dat ve dvou variantách. U první z nich dochází ke klasifikaci W, N3 a REM, u druhé varianty již k rozlišení všech fází najednou W, N1, N2, N3 a REM.


### 5.1 Vícevrstvá neuronová síť

Prvním klasifikátorem je vícevrstvá neuronová síť s typem učení BP, který byl popsán v kapitole 3.3.1.1. Počet vstupů je roven počtu vybraných parametrů, v našem případě 20 vstupům. Počet výstupů odpovídá počtu klasifikovaných fází, u první varianty třem (W, N3 a REM) a u druhé varianty pěti (W, N1, N2, N3, REM) výstupům. Síť se skládá ze vstupní vrstvy, výstupní vrstvy a jedné nebo dvou skrytých vrstev. Při výběru jedné skryté vrstvy bylo testováno 5 – 20 neuronů a za aktivační funkci byla zvolena sigmoidální funkce, zatímco ve výstupní vrstvě byla zvolena lineární aktivační funkce. Schéma popsané neuronové sítě je zobrazeno na obr. 21.



Obr. 21 Schéma neuronové sítě s 1 skrytou vrstvou

Při výběru dvou skrytých vrstev bylo zvoleno v první skryté vrstvě 15 – 20 neuronů a ve druhé vrstvě 10 – 15 neuronů, přičemž byly vyzkoušeny všechny kombinace. Za aktivační funkce skrytých vrstev byly zvoleny opět sigmoidální funkce. Na obr. 22 je zobrazeno schéma neuronové sítě pro dvě skryté vrstvy.



Obr. 22 Schéma neuronové sítě se 2 skrytými vrstvami

### 5.1.1 Praktická realizace neuronové sítě

Základem aplikace neuronové sítě je vstupní neboli učební množina, na které se síť učí (trénuje). V prvním případě učební množina obsahuje sadu 20 vybraných příznaků vypočtených pro jednotlivé 30s epochy pěti signálů u spánkových fází, které klasifikujeme. V našem případě pro 3 nebo 5 spánkových fází, záleží, jestli klasifikujeme pouze W, N3 a REM fáze nebo všechny fáze najednou. Velikost učební množiny je tak závislá na počtu vybraných klasifikovaných fází. Ve druhém případě je rozdíl v tom, že učební množina je zvolena pomocí příkazu *dividerand* jako náhodných 60 % epoch šesti dostupných signálů a zbylých 40 % epoch představuje testovací množinu.

Dále byla vytvořena matice požadovaných výstupů, kde řádky reprezentují jednotlivé spánkové fáze, které klasifikujeme a sloupce jednotlivé epochy. Jedná se o matici nul, pouze příslušnost dané epochy k odpovídající spánkové fázi je reprezentována jedničkou. Toto přiřazení jednotlivých epoch k daným spánkovým fázím vychází z dřívějšího hodnocení somnologa, které měl každý signál k dispozici.

K vytvoření objektu neuronové sítě byl použit příkaz *feedforwardnet* se 2 vstupními proměnnými:  $net = feedforwardnet(hiddenSizes, trainFcn)$ . Proměnná *hiddenSizes* udává počty neuronů v jednotlivých skrytých vrstvách a *trainFcn*, kde se volí trénovací funkce, zde zvolena funkce *trainlm*. Jedná se o Levenberg-Marquardtův algoritmus zpětného šíření chyby, což je iterativní numerická metoda sloužící k určení minima funkce, kdy dochází k předložení všech vzorů současně [39]. Patří k nejrychlejším BP algoritmům, avšak požaduje větší paměť počítače. Výstupním parametrem je struktura *net*, ve které jsou uloženy parametry vytvořené sítě.

Dalším krokem je konfigurace neuronové sítě pomocí příkazu  $net = configure(net, p, t)$ , kde parametr *p* udává učební množinu a parametr *t* matici požadovaných výstupů. Tato data jsou nastavena tak, aby si navzájem co nejlépe odpovídala.

V dalším kroku dochází k procesu trénování neuronové sítě příkazem  $net = train(net, p, t)$ , jehož vstupní parametry již byly popsány výše. Při učení je nastaven také maximální počet učebních iterací (epoch) na 500 příkazem *net.trainParam.epochs* udávající maximální počet epoch, které se má neuronová síť naučit a nejvyšší přípustná kvadratická chyba *net.trainParam.goal* na 0,01, která udává, při jaké hodnotě chybové funkce má být učení sítě zastaveno. Výstupem funkce *train* je naučená síť *net*, které jsou na závěr předložena data, která mají být klasifikována.



Výsledek klasifikace je zobrazen pomocí tzv. matice záměn (*plotconfusion*), kdy se hodnotí správnost klasifikace dané epochy na základě známého požadovaného výstupu. V tab. 9 je zobrazena matice záměn při klasifikaci do dvou tříd „+“ a „-“. Ve sloupcích jsou uvedeny skutečné výstupy klasifikátoru a v řádcích požadované výstupy, na základě nichž se klasifikátor učí. TP (true positive, správně pozitivní) značí počet epoch, které jsou správně zařazeny do třídy „+“, FP (false positive, falešně pozitivní) je počet epoch, které jsou špatně zařazeny do třídy „+“, tyto epochy patří do třídy „-“. TN (true negative, správně negativní) je počet epoch správně přiřazených do třídy „-“ a FN (false negative, falešně negativní) je počet epoch, které jsou chybně zařazeny do třídy „-“, tyto epochy patří do třídy „+“. [24]

Tab. 9 Matice záměn

Požadovaný výstup	Výstup sítě	
	+	-
+	TP	FN
-	FP	TN

Z matice záměn lze již vypočítat úspěšnost popřípadě chybovost klasifikátoru. Celková úspěšnost je vypočtena jako relativní počet správně klasifikovaných epoch [24]:

$$\text{Úspěšnost} = \frac{TP + TN}{TP + TN + FP + FN} \quad (21)$$

Celková chyba je spočtena jako relativní počet chybně klasifikovaných epoch [24]:

$$\text{Chybovost} = \frac{FP + FN}{TP + TN + FP + FN} \quad (22)$$

Dalšími charakteristikami, které lze vypočítat z matice záměn, jsou senzitivita a specificita. Senzitivita udává podíl správně klasifikovaných epoch do třídy „+“ ze všech epoch popsanych třídou „+“, zatímco specificita udává, u kolika epoch popsanych třídou „-“ jsme tuto třídu správně klasifikovali. Avšak tyto charakteristiky v této práci počítat nebudeme. [24]

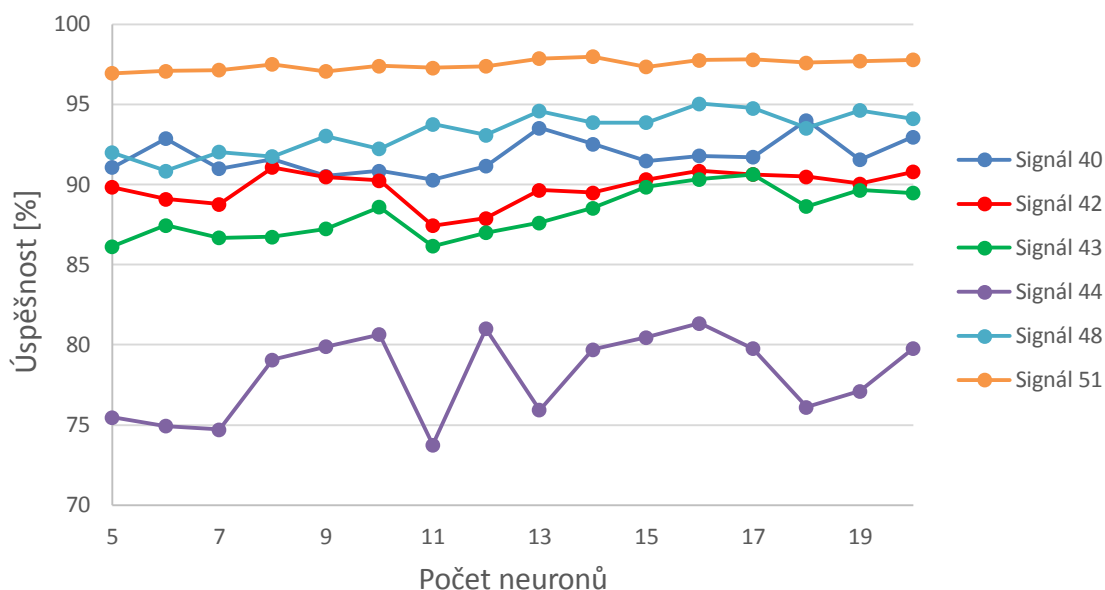
### 5.1.2 Klasifikace W, N3 a REM fáze

Při klasifikaci W, N3 a REM fáze je v první variantě učební množina vytvářena sadou 20 příznaků, které byly vypočteny pro 30s epochy 5 signálů právě u těchto 3 spánkových fází. Testovací množina je tvořena 6. signálem, který nebyl použit při učení. Tento postup křížové validace se opakuje, dokud není pro testování použit každý dostupný signál. V tab. 10 vidíme počty epoch, na kterých se jednotlivé neuronové sítě učí a na kterých se testují.

Tab. 10 Počty epoch pro učící a testovací množiny


<b>Učící množina</b>	<b>W</b>	<b>N1</b>	<b>N2</b>	<b>N3</b>	<b>REM</b>	<b>Celkem W, N3 a REM epoch</b>	<b>Celkem všech epoch</b>
40, 42, 43, 44, 48	763	789	1197	501	391	1655	3641
40, 42, 43, 44, 51	756	643	1480	544	521	1821	3944
40, 42, 43, 48, 51	739	498	1562	661	543	1943	4003
40, 42, 44, 48, 51	542	816	1300	566	554	1662	3778
40, 43, 44, 48, 51	584	753	1204	593	571	1748	3705
42, 43, 44, 48, 51	776	791	1342	550	410	1736	3869
<b>Testovací množina</b>	<b>W</b>	<b>N1</b>	<b>N2</b>	<b>N3</b>	<b>REM</b>	<b>Celkem W, N3 a REM epoch</b>	<b>Celkem všech epoch</b>
51	69	69	420	182	207	458	947
48	76	215	137	139	77	292	644
44	93	360	55	22	55	170	585
43	290	42	317	117	44	451	810
42	248	105	413	90	27	365	883
40	56	67	275	133	188	377	719

Nejdříve byla zvolena 1 skrytá vrstva s proměnným počtem neuronů 5 – 20. Pro určení optimálního nastavení počtu neuronů byla do grafu vynesena závislost úspěšnosti klasifikace jednotlivých signálů na počtu neuronů. Při každém novém nastavení počtu neuronů bylo provedeno 10 na sobě nezávislých učení a testování sítě, čímž se lépe zamezí vlivu náhodného nastavení počátečních váhových hodnot neuronů. Proto každá hodnota vynesena v grafu (reprezentující výstupní úspěšnost) byla vypočtena jako průměrná hodnota deseti získaných úspěšností. Jak můžeme vidět z obr. 23, úspěšnost u signálu 51 není téměř vůbec ovlivněna volbou počtu neuronů. Zbylé signály také nevykazují významný trend, pomocí kterého by se dal zvolit optimální počet neuronů. Proto pro každý počet neuronů byl vypočten průměr z 6 výstupních úspěšností a zjištěná maximální hodnota získaná pro 16 neuronů byla zvolena za optimální.



Obr. 23 Závislost úspěšnosti neuronové sítě na počtu neuronů v jedné skryté vrstvě

Na obr. 24 je znázorněna úspěšnost klasifikace jednotlivých signálů pro 1 skrytou vrstvu a 16 neuronů. Každý krabicový graf je tvořen 10 hodnotami, odpovídající jednotlivým úspěšnostem při deseti naučení a testování sítě, jejichž průměrná hodnota je zobrazena v tab. 11. Lze vidět, že nejvyšší úspěšnosti dosáhl signál 51, který byl učen na signálech 40, 42, 43, 44 a 48. Naopak nejnižší úspěšnost byla zaznamenána u signálu 44, jehož průměrná úspěšnost je rovna 81,4 %. Zároveň si lze u tohoto signálu všimnout největšího rozptylu hodnot.



Obr. 24 Krabicové grafy úspěšnosti signálů pro 1 skrytou vrstvu a 16 neuronů při klasifikaci W, N3 a REM fáze

Při klasifikaci W, N3 a REM fáze se úspěšnost klasifikace liší u jednotlivých signálů. Zatímco nejlépe klasifikovaný signál dosahuje úspěšnosti téměř 98 %, nejhůře klasifikovaný signál pouze okolo 81 %. Může to být zapříčiněno tím, že testovací množina toho signálu (signál 44) dosahuje menšího počtu epoch než u zbývajících signálů, jak lze vidět z tab. 10.

Tab. 11 Průměrné hodnoty úspěšnosti u jednotlivých signálů

Klasifikovaný signál	Úspěšnost [%]
40	91,8
42	90,8
43	90,3
44	81,4
48	95,0
51	97,8

Pro ukázkou je v tab. 12 zobrazena náhodně vybraná matice záměn při testování neuronové sítě u signálu 40. Jak již bylo řečeno, učební množina je tvořena 5 signály, neuronová síť je tvořena jednou skrytou vrstvou obsahující 16 neuronů a sigmoidální aktivační funkci, zatímco u výstupní vrstvy byla zvolena funkce lineární. Jako u ostatních případů i zde byla zvolena trénovací funkce *trainlm*.


Tab. 12 Matice záměn testování signálu 40 při klasifikaci W, N3 a REM fáze

	W	N3	REM	Úspěšnost Chybovost
W	47 12,5 %	0 0,0 %	14 3,7 %	77,0 % 23,0 %
N3	0 0,0 %	133 35,3 %	0 0,0 %	100,0 % 0,0 %
REM	9 2,4 %	0 0,0 %	174 46,2 %	95,1 % 4,9 %
Úspěšnost Chybovost	83,9 % 16,1 %	100,0 % 0,0 %	92,6 % 7,4 %	93,9 % 6,1 %

V tomto případě byla fáze N3 správně klasifikována ve všech případech. Fáze W a N3 patří mezi dvě nejrozdílnější fáze, proto byl tento výsledek očekáván. Naopak nižší míra úspěšnosti byla zaznamenána u W i REM fáze. Ve 14 případech došlo ke špatné klasifikaci fáze W a v 9 případech k nesprávné klasifikaci fáze REM.

Při zvolení 2 skrytých vrstev s 15 – 20 neurony v první a s 10 – 15 neurony ve druhé skryté vrstvě, jak můžeme vidět i z obr. 25, nedošlo ke zvýšení úspěšnosti klasifikace u jednotlivých signálů oproti variantě s 1 skrytou vrstvou. Díky tomuto důvodu a zároveň kvůli vyšší výpočetní náročnosti, nastavení se dvěma skrytými vrstvami, při klasifikaci W, N3 a REM fáze, využívat nebudeme. Pro získání

objektivnějšího výsledku bylo stejně jako v předchozím případě provedeno deset nezávislých učení a testování sítě s daným nastavením. Každá hodnota uvedená v grafu byla vypočtena jako průměrná hodnota 10 úspěšností z těchto jednotlivých testování.



Obr. 25 Závislost úspěšnosti neuronové sítě na počtu neuronů ve dvou skrytých vrstvách


V práci byla zvolena pro klasifikaci W, N3 a REM fáze ještě druhá varianta, kde část ze všech 6 signálů byla určena pro trénování a část pro testování. Konkrétně náhodných 60 % epoch tvořilo učební množinu a 40 % testovací množinu. Zde se očekávaly lepší výsledky než u předchozí varianty. Nicméně se nejedná o variantu, která by měla uplatnění v klinické praxi. Nastavení neuronové sítě bylo zvoleno takové, které bylo v předchozí variantě zvoleno za optimální. Jedná se tak o neuronovou síť s 1 skrytou vrstvou obsahující 16 neuronů. Trénovací funkce stejně jako aktivační funkce zůstávají se stejným nastavením.

Úspěšnost této klasifikace byla vypočtena opět jako průměrná hodnota z deseti hodnot a rovná se 95,2 %. Srovnáme-li úspěšnost tohoto postupu s předcházejícím, předpoklad o zvýšení míry úspěšnosti se potvrdil, ovšem kromě signálu 51, jehož úspěšnost dosáhla vyšší hodnoty.

### 5.1.3 Klasifikace všech spánkových fází


Učební množina byla doplněna o další dvě fáze N1 a N2. Tyto fáze se vyznačují velkou vzájemnou podobností a zároveň podobností k fázi W. Proto lze očekávat, že získané výsledky budou dosahovat nižších hodnot než u předchozího případu. Při klasifikaci W, N1, N2, N3 a REM fáze je opět v první variantě učební množina tvořena sadou 20 příznaků vypočtených pro 30s epochy 5 signálů u zmíněných 5 fází. Šestý signál opět slouží k testování. Počty epoch jednotlivých učících a testovacích množin jsou také uvedeny v tab. 10. Při volbě jedné skryté vrstvy s proměnným počtem neuronů 5 – 20

nebo dvou skrytých vrstev, s volitelným počtem neuronů v jednotlivých vrstvách jako v předchozím případě, nevidíme významnou závislost mezi zvoleným počtem neuronů a úspěšností klasifikace, viz obr. 26. Navíc při volbě dvou skrytých vrstev opět nedošlo ke zvýšení míry úspěšnosti. Proto za vhodné nastavení byla zvolena neuronová síť s 1 skrytou vrstvou obsahující 6 neuronů. Počet neuronů byl zvolen stejným způsobem jako při klasifikaci W, N3 a REM fáze a to výpočtem průměrné hodnoty z šesti výstupních úspěšností pro každý počet neuronů, kde maximální průměrná hodnota odpovídala zvoleným šesti neuronům.



Obr. 26 Závislost úspěšnosti neuronové sítě na počtu neuronů v jedné skryté vrstvě při klasifikaci všech fází

Stejně jako v předchozích případech bylo provedeno pro jednotlivé signály a pro dopřednou neuronovou síť tvořenou jednou skrytou vrstvou obsahující 6 neuronů 10 učení a testování sítě. Získané výsledky byly znázorněny na obr. 27 pomocí krabicových grafů. Nejvyšší úspěšnosti opět dosahuje signál 51, naopak výrazně nižší úspěšnost se vyskytuje u signálu 44. Průměrné hodnoty úspěšnosti pro jednotlivé signály jsou znázorněny v tab. 13.



Obr. 27 Krabicové grafy úspěšnosti signálů pro 1 skrytou vrstvu a 6 neuronů při klasifikaci všech fází

Při klasifikaci všech fází lze vidět výrazné rozdíly v úspěšnosti klasifikace u jednotlivých signálů. Zatímco nejvyšší úspěšnost byla zaznamenána u signálu 51, kde průměrná hodnota vychází 76 %, nejnižší úspěšnost vyskytující se u signálu 44 činila pouhých 29 %.

Tab. 13 Průměrné hodnoty úspěšnosti u 6 signálů při klasifikaci všech fází

Klasifikovaný signál	Úspěšnost [%]
40	73,3
42	71,8
43	67,8
44	29,3
48	53,9
51	76,3

Zvolili jsme si signál s nejnižší úspěšností a zobrazili jsme si náhodně jeho jednu matici záměn, viz tab. 14. Podle předpokladů je problematická zejména klasifikace mezi W a N1 fází, kdy W fáze byla ve 248 případech klasifikována jako N1 fáze. K chybné klasifikaci rovněž došlo mezi N1 a N2 fází, kdy v 67 případech byla N2 fáze chybně označena za N1 fázi. N1 fáze je kromě W a N2 fáze také zaměňována s REM fází. Z výsledků plyne, že největší problémy při klasifikaci způsobuje spánková fáze N1.

Tab. 14 Matice záměn testování signálu 44 při klasifikaci všech fází

	W	N1	N2	N3	REM	Úspěšnost Chybovost
W	<b>91</b> 15,6 %	248 42,4 %	14 2,4 %	2 0,3 %	0 0,0 %	25,6 % 74,4 %
N1	0 0,0 %	<b>10</b> 1,7 %	5 0,9 %	9 1,5 %	0 0,0 %	41,7 % 58,3 %
N2	0 0,0 %	67 11,5 %	<b>35</b> 6,0 %	0 0,0 %	0 0,0 %	34,3 % 65,7 %
N3	2 0,3 %	2 0,3 %	1 0,2 %	<b>11</b> 1,9 %	0 0,0 %	68,8 % 31,3 %
REM	0 0,0 %	33 5,6 %	0 0,0 %	0 0,0 %	<b>55</b> 9,4 %	62,5 % 37,5 %
Úspěšnost Chybovost	97,8 % 2,2 %	2,8 % 97,2 %	63,6 % 36,4 %	50,0 % 50,0 %	100,0 % 0,0 %	34,5 % 65,5 %

Pro porovnání byla v tab. 15 zobrazena náhodná matice záměn pro signál 51, který dosahoval nejvyšší úspěšnosti. I zde se vyskytly problémy při rozeznání fází W – N1 a N1 – N2, nicméně nikoliv v takové míře jako u signálu 44. K chybné klasifikaci také docházelo při rozeznání fáze N2 od fází W, N3 a REM.

Tab. 15 Matice záměn testování signálu 51 při klasifikaci všech fází

	W	N1	N2	N3	REM	Úspěšnost Chybovost
W	<b>64</b> 6,8 %	31 3,3 %	15 1,6 %	1 0,1 %	0 0,0 %	57,7 % 42,3 %
N1	1 0,1 %	<b>9</b> 1,0 %	19 2,0 %	0 0,0 %	12 1,3 %	22,0 % 78,0 %
N2	1 0,1 %	17 1,8 %	<b>342</b> 36,1 %	15 1,6 %	34 3,6 %	83,6 % 16,4 %
N3	1 0,1 %	3 0,3 %	25 2,6 %	<b>166</b> 17,5 %	0 0,0 %	83,6 % 16,4 %
REM	2 0,2 %	9 1,0 %	19 2,0 %	0 0,0 %	<b>161</b> 17,0 %	84,3 % 15,7 %
Úspěšnost Chybovost	92,8 % 7,2 %	13,0 % 87,0 %	81,4 % 18,6 %	91,2 % 8,8 %	77,8 % 22,2 %	78,4 % 21,6 %

Při klasifikaci všech fází pomocí varianty, kdy ze všech šesti signálů je z jejich 60 % náhodně vybraných epoch vytvořena učební množina a na zbylých 40 % dochází ke klasifikaci, získáváme hodnotu úspěšnosti 76,9 %. Opět byla tato hodnota získána průměrováním deseti hodnot. Podle předpokladů dosahuje úspěšnost získaná tímto postupem vyšších hodnot než u předešlého postupu.

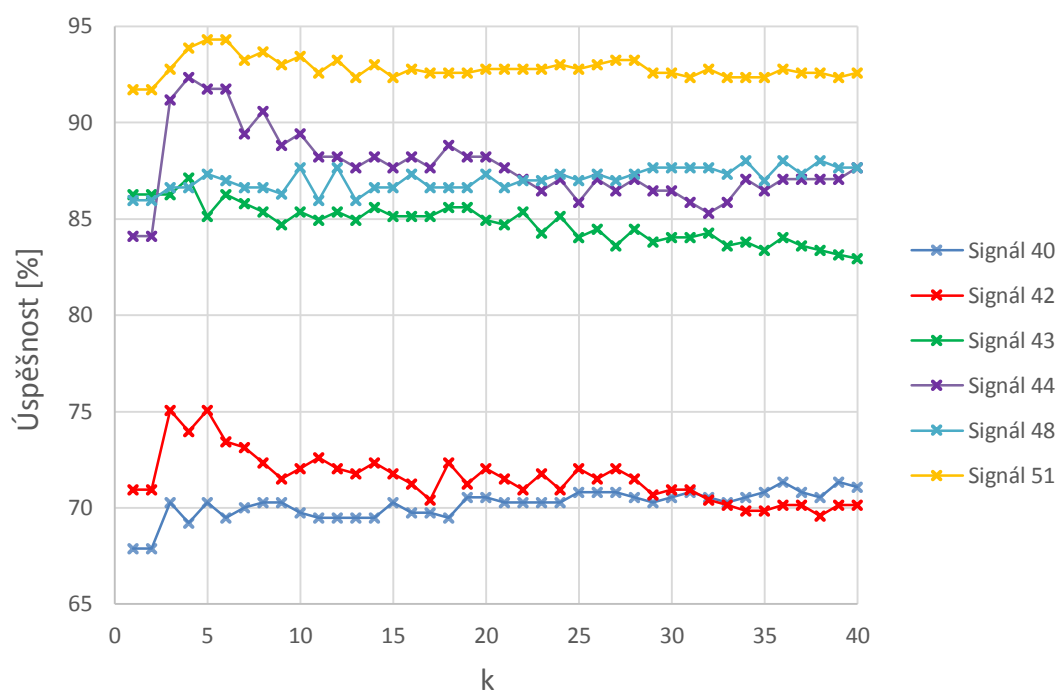


## 5.2 k-NN klasifikátor


k-NN klasifikátor založený na podobnosti s nejbližšími sousedy byl realizován pomocí implementované funkce Matlabu *knnclassify*, kde vstupními parametry je matice *Sample*, jejíž řádky mají být klasifikovány do jednotlivých spánkových fází. Počet sloupců této matice, odpovídající počtu vybraných příznaků, musí být stejný jako u matice *Training*, kde každému jejímu řádku je přiřazena spánková fáze na základě vektoru *Group*. Tento vektor požadovaných výstupů vznikl na základě hodnocení somnologa, kdy jednotlivé číslice odpovídají daným spánkovým fázím: 0 – W, 1 – N1, 2 – N2, 3 – N3 a 5 – REM. Dalším vstupním parametrem je konstanta *k*, která udává počet nejbližších sousedů použitých při klasifikaci, a volba vzdálenostní metriky, v našem případě euklidovské vzdálenosti, která slouží ke stanovení vzdálenosti mezi dvěma objekty. Výstupním parametrem je vektor *Class*, který udává přiřazení jednotlivých 30s epoch jednotlivým spánkovým fázím pomocí k-NN klasifikátoru. Zde je uvedena realizace k-NN klasifikátoru v programovém prostředí Matlab: `Class = knnclassify(Sample, Training, Group, k, 'euclidean')`.

Při klasifikaci pomocí k-NN klasifikátoru je v první variantě matice *Sample* tvořena jedním signálem, počet sloupců této matice je roven dvaceti, což odpovídá počtu příznaků. Počet řádků je závislý na počtu epoch, které klasifikujeme. Matice *Training* je tvořena zbylými pěti signály. Konstanta *k* udávající počet nejbližších sousedů byla volena v rozmezí 1 až 40. Jak již bylo zmíněno výše, klasifikujeme W, N3 a REM fázi a také všechny fáze najednou.

Na obr. 28 a obr. 29 vidíme závislost úspěšnosti klasifikátoru na parametru *k* při klasifikaci fází W, N3 a REM a ve druhém případě při klasifikaci všech fází W, N1-N3 a REM. V prvním případě při klasifikaci W, N3 a REM fáze byla za optimální hodnotu parametru *k* zvolena hodnota  $k = 5$  a při klasifikaci všech fází  $k = 22$ . Optimální hodnota byla zvolena tak, že pro každou hodnotu *k* byl vypočten průměr z 6 získaných úspěšností (máme 6 signálů) a poté zjištěno, pro které *k* je vypočtená hodnota maximální.



Obr. 28 Závislost úspěšnosti k-NN klasifikátoru při rozlišení W, N3 a REM fáze na parametru  $k$



Obr. 29 Závislost úspěšnosti k-NN klasifikátoru při rozlišení všech fází na parametru  $k$

V tab. 16 ve druhém sloupci je znázorněna úspěšnost klasifikace W, N3 a REM fáze pro  $k = 5$  a jednotlivé signály. Jak již bylo řečeno, na pěti signálech dochází k naučení a u šestého signálu k samotné klasifikaci. Největší úspěšnosti dosahuje signál 51, který byl naučen na signálu 40, 42, 43, 44 a 48, jeho úspěšnost je 94,3 %, naopak nejmenší úspěšnost je u signálu 40, jehož úspěšnost činí 70,3 %. V posledním sloupci jsou výsledky klasifikace všech fází. Nejvyšší úspěšnost byla opět dosažena u signálu 51 a zároveň u signálu 42, naopak nejnižší u signálu 44. Jak lze vidět, u signálu 44 došlo k největšímu poklesu úspěšnosti, srovnáme-li klasifikaci pouze W, N3 a REM fáze a všech fází najednou.

Tab. 16 Úspěšnost klasifikace W, N3 a REM fáze pro  $k = 5$  a u všech fází pro  $k = 22$ .

Klasifikovaný signál	Úspěšnost [%], fáze W, N3, REM	Úspěšnost [%], všechny fáze
40	70,3	61,6
42	75,1	65,7
43	85,1	62,7
44	91,8	33,7
48	87,3	49,8
51	94,3	65,7

Pomocí druhé varianty, kdy náhodných 60 % epoch šesti signálů tvoří učební množinu a zbylých 40 % testovací množinu, byla při klasifikaci W, N3 a REM fáze získána úspěšnost 91 %. Tato hodnota byla vypočtena jako průměrná hodnota deseti hodnot. Srovnáme-li tyto výsledky s výsledky předchozí varianty uvedené v tab. 16, je předpoklad o zvýšení úspěšnosti potvrzen pouze u signálů 40, 42, 43 a 48. Při klasifikaci všech fází byla dosažena průměrná úspěšnost 71,1 %. Při srovnání s hodnotami z předchozí varianty lze vidět, že podle předpokladu došlo ke zvýšení úspěšnosti.

### 5.3 Lineární diskriminační analýza

Dalším vybraným klasifikátorem je klasifikace pomocí lineární diskriminační analýzy, jež byla popsána v kapitole 3.3.4. Samotná realizace byla provedena pomocí příkazu *classify*, kde jejími vstupy je opět matice *Sample*, *Training* a vektor *Group*, jako u předchozího klasifikátoru. Posledním parametrem je volba diskriminační funkce, která je defaultně nastavena na funkci lineární: `Class = classify(Sample, Training, Group, 'linear')`. Výstupním parametrem je vektor, který udává, do které třídy (tj. spánkové fáze) je daná epocha přiřazena. Následně je vypočtena úspěšnost klasifikátoru.

Jak již bylo řečeno, při klasifikaci pomocí toho klasifikátoru je matice *Sample*, *Training* i *Group* totožná jako u předešlého klasifikátoru. V tab. 17 jsou zobrazeny získané hodnoty úspěšností.

Tab. 17 Úspěšnost klasifikace W, N3 a REM fáze a u všech fází pomocí LDA

Klasifikovaný signál	Úspěšnost [%], fáze W, N3, REM	Úspěšnost [%], všechny fáze
40	92,8	71,5
42	90,4	67,3
43	84,3	57,9
44	84,7	35,2
48	92,8	51,1
51	96,1	67,6

Srovnáme-li dosažené výsledky s výsledky získané pomocí k-NN klasifikátoru, u většiny signálů dochází ke zvýšení úspěšnosti klasifikace. Největší rozdíl je vidět u signálu 40, kdy se při klasifikaci W, N3 a REM fáze úspěšnost zvýšila o více než 20 % a při klasifikaci všech fází o 10 %. Na druhou stranu výsledky získané pomocí neuronové sítě dosahují obecně vyšších hodnot, nicméně její nevýhoda je ve vyšší výpočetní náročnosti.

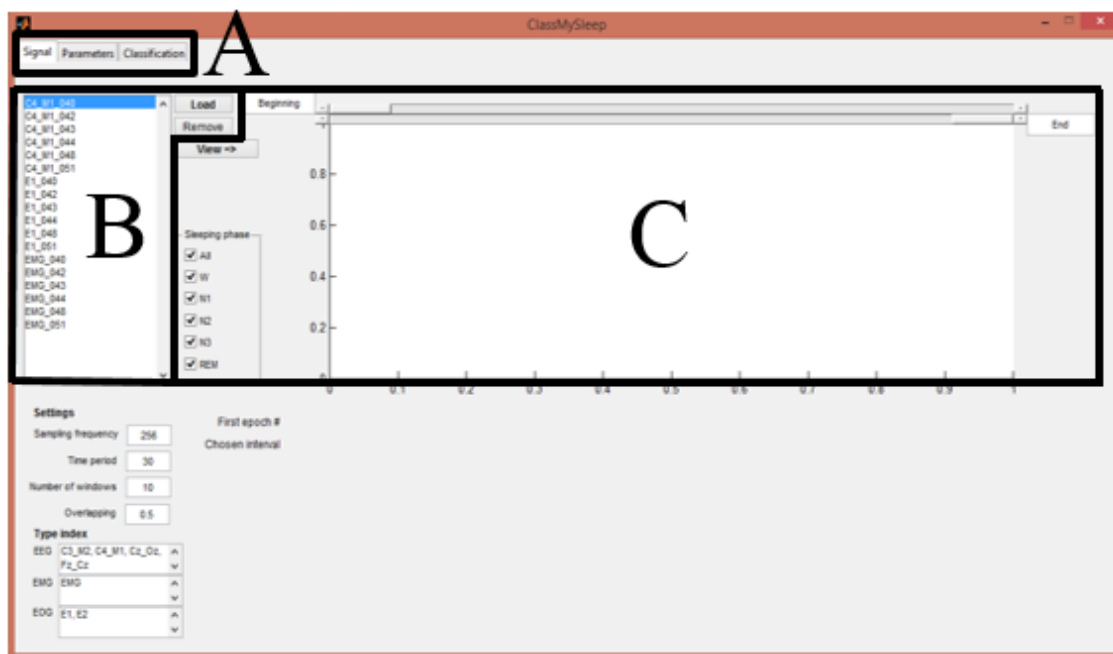
Úspěšnost klasifikace získaná pomocí druhé varianty, kdy jsou data náhodně rozdělena na učební a testovací množinu, vychází pro klasifikaci W, N3 a REM fáze 95,3 % a při klasifikaci všech fází 72,5 %. V obou případech dosáhla úspěšnost vyšších hodnot než při klasifikaci pomocí k-NN klasifikátoru.

## 6 POPIS PROGRAMU V PROSTŘEDÍ MATLAB

V programovém prostředí Matlab verze R2011a byl vytvořen program s grafickým uživatelským rozhraním (angl. Graphic User Interface, GUI), ve kterém dochází k výběru PSG signálů, analýze a následné klasifikaci. Toto grafické uživatelské rozhraní bylo vytvořeno pomocí nástroje GUIDE (angl. Graphical User Interface Development Environment), které je implementováno v prostředí Matlab.

Program se skládá ze souboru s příponou \*.fig (*ClassMySleep.fig*), který obsahuje popis grafické části GUI a ze souboru s příponou \*.m s názvem *ClassMySleep.m*, který obsahuje zdrojový kód ovládající příslušné GUI. Tento soubor vyvolává funkce uložené ve složce *Funkce*, které slouží k provedení dílčích částí programu. Součástí je také složka *Data*, která obsahuje soubory s příponou \*.mat, jedná se o signály a jejich hodnocení somnologem.

Pomocí souboru *ClassMySleep.m* spustíme program, jehož pracovní okno je zobrazeno na obr. 30. V jeho horní části si vybíráme ze tří panelů (obr. 30 A). V prvním z nich nazývaný *Signal* dochází k vybrání a nahrání signálů a k zobrazení signálů. Druhý panel *Parameters* slouží k výběru a výpočtu parametrů, dále k výběru vhodných parametrů pomocí dopředné selekce a také ke spojení dat jednotlivých PSG signálů. Třetí panel *Classification* slouží k samotné klasifikaci, kde si lze vybrat ze tří klasifikátorů.

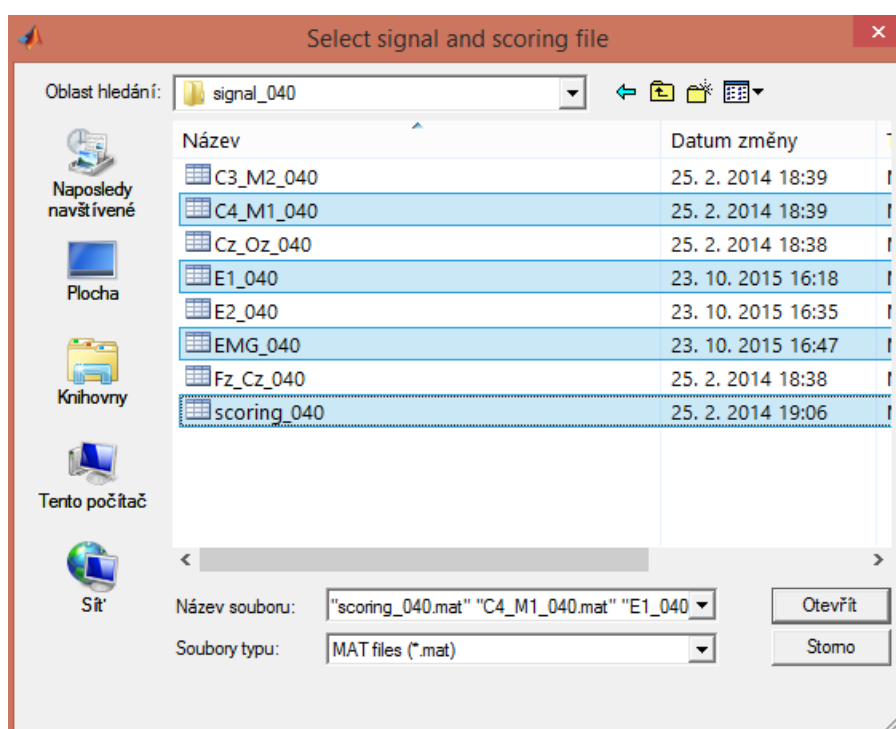


Obr. 30 Pracovní okno souboru ClassMySleep

## 6.1 Panel *Signal*


V první části tohoto panelu si pomocí tlačítka *Load* nahrajeme námi vybrané signály do příslušného rozbalovacího seznamu, do kterého se pro přehlednost zapisují podle abecedy daných kanálů (obr. 30 B). Při úspěšném či neúspěšném nahrání signálu jsme upozorněni hláškou. Naopak pomocí tlačítka *Remove* lze vybrané signály vymazat.

Po vybrání tlačítka *Load* se zobrazí výběrové okno se složkou *Data*, kde si uživatel vybere soubor daného pacienta, který obsahuje signály ze 4 EEG kanálů (C3\_M2, C4\_M1, Cz\_Oz, Fz\_Cz), 2 EOG kanálů (E1, E2), 1 EMG kanálů (EMG) a soubor scoring, viz obr. 31. Je nutné vždy při výběru jednoho či více signálů nahrát i soubor scoring, který obsahuje hodnocení daného signálu somnologem. Pokud není vybrán i soubor scoring, objeví se chybová hláška.



Obr. 31 Okno pro výběr signálů a jeho hodnocení vybraného pacienta

Pomocí tlačítka *View* si lze vybraný signál zobrazit do speciálního okna, viz obr. 30 C. Na panelu spánkové fáze *Sleeping phase* si pomocí zaškrtnutých políček vybereme, které spánkové fáze chceme zobrazit. Lze zvolit všechny spánkové fáze (celý signál), některé z nich nebo pouze jednu spánkovou fázi. Na obr. 32 je zobrazena ukázka signálu 48, konkrétně EEG kanálu C4\_M1, o délce 19 320 s (644 epoch o délce 30 s), přičemž byly vybrány všechny fáze.



Obr. 32 Ukázka zobrazení signálu

## 6.2 Panel *Parameters*

V panelu *Parameters* dochází v levé části k výběru jednoho či více signálů, ze kterých chceme počítat vybrané parametry. Použité signály byly snímány se vzorkovací frekvencí 256 Hz, která je zde nastavena jako defaultní. Avšak je zde ponechána možnost změny této hodnoty v případě nahrání signálů s odlišnou vzorkovací frekvencí. V nastavení je kromě vzorkovací frekvence možnost volby délky epochy, která je zde nastavena na 30 s.

U EEG signálů je možnost volby příznaků v časové, frekvenční a časově-frekvenční oblasti. Celkově se jedná o 10 příznaků v časové oblasti, 5 příznaků ve frekvenční oblasti a 25 příznaků v časově-frekvenční oblasti. Při výpočtu parametrů ve frekvenční oblasti pomocí periodogramu je každá epocha rozdělena pomocí okna na kratší úseky. Je zde defaultně nastaveno 10 oken v rámci jedné epochy, délka okna odpovídá 3 s při délce epochy 30 s. Navíc je zde nastaveno překrytí sousedních na 0,5 (50% překrytí). Obě tyto hodnoty se dají nastavit v nastavení v levé části tohoto panelu. U EMG signálů se dají příznaky počítat v časové a frekvenční oblasti, celkově se jedná o 11 příznaků a u EOG signálů pouze v časové oblasti.

U všech signálů dochází podle jejich názvu k určení, o který PSG signál se jedná. Toto přiřazení je zobrazeno v levé dolní části pomocí tří polí, viz obr. 33. Pokud vybereme signál s jiným názvem, než který je v těchto polích uveden, nedojde u tohoto signálu k výpočtu příznaků. Proto je nutné tento nový název do příslušného pole zapsat. Popsané přiřazení slouží k tomu, abychom zabránili výpočtu příznaků, které nepřísluší danému PSG signálu.

Type index	
EEG	C3_M2, C4_M1, Cz_Oz, Fz_Cz
EMG	EMG
EOG	E1, E2

Obr. 33 Názvy jednotlivých PSG signálů

Na obr. 34 jsou zobrazeny příznaky, které si volíme pomocí zaškrtačacích políček. Po výběru příznaků si můžeme tento výběr příznaků uložit pomocí tlačítka *Save settings*, toto nastavení se uloží do složky *Data*. Pomocí tlačítka *Load settings* lze námi uložené nastavení kdykoliv načíst. Poté co si vybereme či načteme příznaky, přecházíme do pole *Operations with parameters*, kde po stisknutí tlačítka *Compute* vybrané příznaky vypočteme. Nesmíme však před výpočtem zapomenout na výběr signálů, ze kterých dané příznaky chceme počítat. Vypočtené příznaky lze uložit pomocí tlačítka *Save* nebo si již dříve uložené vypočtené příznaky znovu načíst tlačítkem *Load*. Při výpočtu parametrů je pomocí ukazatele průběhu znázorněno, kolik procent nám zbývá do konce.

### EEG parameters

<b>Time domain</b>	<b>Frequency domain</b>
<input type="checkbox"/> Activity	<input type="checkbox"/> Delta
<input type="checkbox"/> Energy	<input type="checkbox"/> Theta
<input type="checkbox"/> Skewness	<input type="checkbox"/> Alfa
<input type="checkbox"/> Entropy	<input type="checkbox"/> Beta 1
<input type="checkbox"/> Mobility	<input type="checkbox"/> Beta 2
<input type="checkbox"/> Percentile 75	(Periodogram)
<input type="checkbox"/> Complexity	
<input type="checkbox"/> Standard Deviation	
<input type="checkbox"/> Mean Value	
<input type="checkbox"/> Curtosis	

**Time-Frequency domain**

Spectral powers of:	Relative powers of:
<input type="checkbox"/> Delta waves	<input type="checkbox"/> Delta waves
<input type="checkbox"/> Theta waves	<input type="checkbox"/> Theta waves
<input type="checkbox"/> Alfa waves	<input type="checkbox"/> Alfa waves
<input type="checkbox"/> Beta waves	<input type="checkbox"/> Beta waves
<input type="checkbox"/> Gamma waves	<input type="checkbox"/> Gamma waves

Entropy of:

<input type="checkbox"/> Delta waves	<input type="checkbox"/> Delta / Theta
<input type="checkbox"/> Theta waves	<input type="checkbox"/> Alfa / Theta
<input type="checkbox"/> Alfa waves	<input type="checkbox"/> Beta / Theta
<input type="checkbox"/> Beta waves	<input type="checkbox"/> Gamma / Theta
<input type="checkbox"/> Gamma waves	<input type="checkbox"/> Alfa / Delta
	<input type="checkbox"/> Beta / Delta
	<input type="checkbox"/> Gamma / Delta
(Wavelet Transformation)	<input type="checkbox"/> Beta / Alfa
	<input type="checkbox"/> Gamma / Alfa
	<input type="checkbox"/> Gamma / Beta

### EMG parameters

**Time domain**

- Activity
- Energy
- Skewness
- Entropy
- Mobility
- Percentile 75
- Complexity
- Standard Deviation
- Mean Value
- Curtosis

**Frequency domain**

- Power 12.5 - 32 Hz

### EOG parameters

**Time domain**

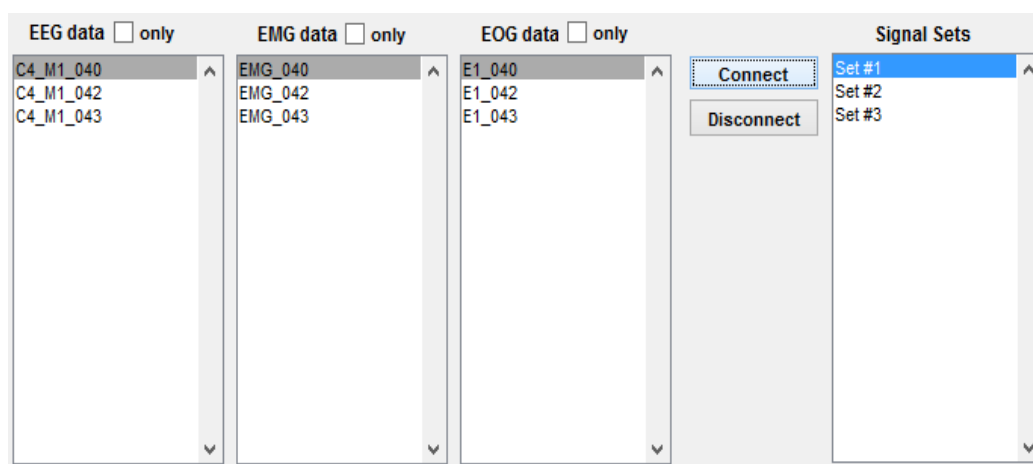
- Activity
- Energy
- Skewness
- Entropy
- Mobility
- Percentile 75
- Complexity
- Standard Deviation
- Mean Value
- Curtosis

Obr. 34 Výběr příznaků u EEG, EMG a EOG signálů



Po výpočtu parametrů lze zaškrtnutím políčka *Remove NaN rows* odstranit nečíselné hodnoty NaN při další práci s daty a také zaškrtnutím políčka *Normalize to interval <0,1>* umožnit normalizaci hodnot jednotlivých parametrů do intervalu <0,1>. Normalizace je provedena odečtením minimální hodnoty parametru od jednotlivých hodnot parametru a následným podělením maximální hodnotou.

Následuje vytvoření datových setů na základě spojení jednotlivých PSG signálů daného pacienta, viz obr. 35. K těmto spojení dochází ve třech rozbalovacích seznamech a stisknutí tlačítka *Connect*. Pokud chceme dané spojení smazat, použijeme tlačítko *Disconnect*. Kdybychom chtěli spojit signály různých pacientů, objeví se hláška, že je spojení kvůli rozdílné délce signálů neplatné. Ke spojení by nedošlo ani v případě chybějících dat v jednom ze tří seznamů, např. pokud bychom nepočítali parametry pro EMG signály. Druhou možností je výběr dat pouze jednoho typu PSG signálů.



Obr. 35 Tvorba datových setů

V tomto panelu je také zabudovaná detekce statisticky významných ze zvolených příznaků pomocí algoritmu dopředné selekce. Tento algoritmus se dá spustit pomocí tlačítka *Run Detection* po vybrání datových setů nebo po volbě pouze daného PSG signálu. Po ukončení algoritmu se statisticky významné příznaky vypíší do pole pod tlačítkem. Tlačítkem *Change settings* se přenastaví zaškrťovací políčka jednotlivých parametrů na parametry vybrané dopřednou selekcí.

V případě načtení dat pomocí *Load* se patřičně nastaví zaškrťovací políčka parametrů, seznamy spočtených PSG signálů a datových setů a zároveň se doplní kompletní seznam signálů o chybějící.

### 6.3 Panel *Classification*

V panelu *Classification* si uživatel v kontextovém menu zvolí, které z PSG signálů nebo datových setů budou využity ke klasifikaci. Jednotlivé sety se následně zobrazí v rozbalovacím seznamu, ve kterém si označíme ta data, která slouží jako vstup následně

zvoleného klasifikátoru. Poté si pomocí zaškrťovacích políček zvolíme, které spánkové fáze chceme klasifikovat. Tato část je společná pro všechny tři zvolené klasifikátory.

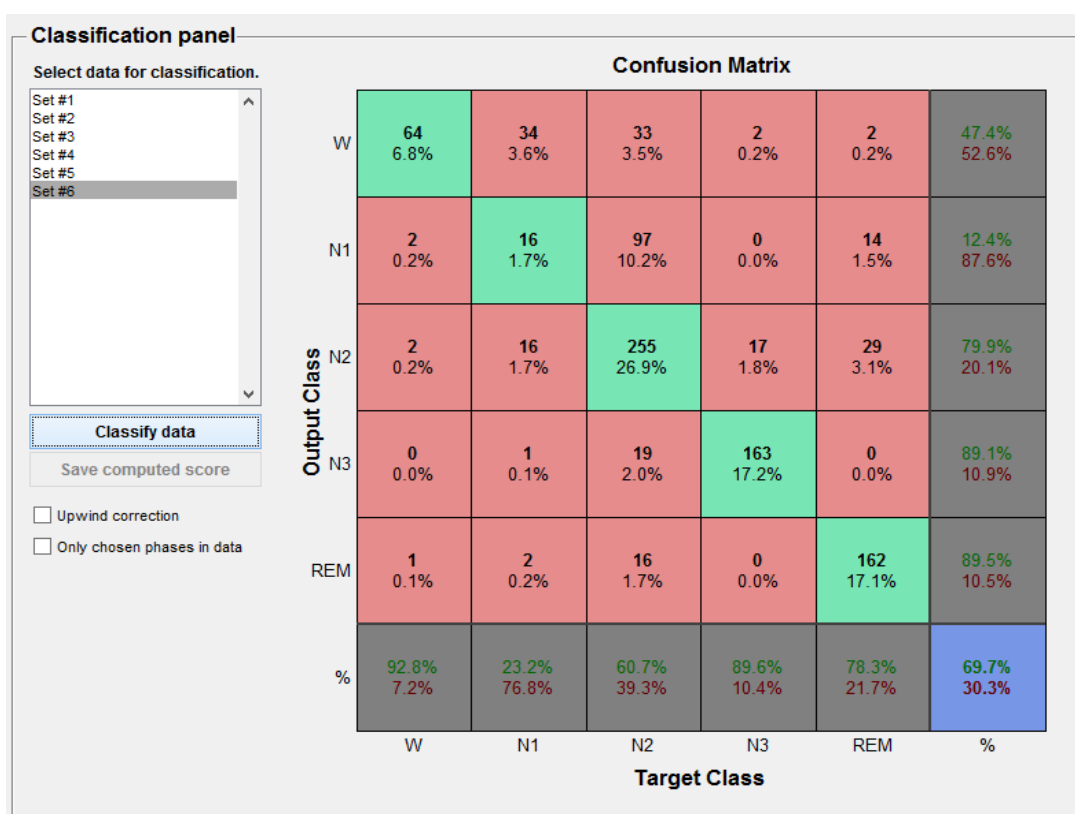
Pomocí kontextového menu následuje volba klasifikátoru. Na výběr je neuronová síť *Multilayer ANN*, k-NN klasifikátor *k-NN algorithm* a algoritmus lineární diskriminační analýzy *Linear Discriminant Analysis*. Při zvolení neuronové sítě si v nastavení zvolíme počet neuronů v první (*1st Layer Neurons*) a popřípadě druhé (*2nd Layer Neurons*) skryté vrstvě, což lze vidět na obr. 36. Dále je zde možnost volby maximálního počtu iterací *Number of Iterations* a cílové přesnosti *Goal precision*. Počet vstupů, počet výstupů a počet trénovacích vzorů je vyplněn automaticky na základě vybraných datových setů a volby fází, které chceme klasifikovat. Opět je tu možnost načtení již uložené neuronové sítě *Load ANN* či uložení neuronové sítě *Save ANN*. K nastavení sítě dochází pomocí tlačítka *Initialize ANN* dle vyplněných polí. V případě změny těchto polí je nutno znovu síť inicializovat. Tlačítko *Start Learning* vyvolá algoritmus učení sítě. Průběh učení je viditelný v případě, že bylo před inicializací sítě zaškrtnuto políčko *NNTrainTool visible*.

The image shows a software interface for configuring a neural network. At the top, there is a dropdown menu labeled 'Choose algorithm for classification.' with 'Multilayer ANN' selected. Below this is a section titled 'ANN algorithm settings'. It contains several interactive elements: a 'Load ANN' button, a 'Save ANN' button, a series of input fields for network parameters (Number of inputs: 20, Number of neurons 1st Layer Neurons: 6, Number of neurons 2nd Layer Neurons: 0, Number of outputs: 5, Number of training patterns: 3641), a checked checkbox for 'NNTrainTool visible', an 'Initialize ANN' button, and another set of input fields for training parameters (Number of iterations: 500, Goal precision: 0.01). At the bottom of the settings panel is a 'Start Learning' button.

Obr. 36 Nastavení neuronové sítě

Po naučení sítě si v klasifikačním panelu *Classification panel*, konkrétně v rozbalovacím seznamu, vybereme data, která bychom chtěli klasifikovat. Seznam

těchto datových souborů je stejný jako seznam, ze kterého se volí vstupy algoritmu. Tento klasifikační panel je zobrazen na obr. 37. Následuje klasifikace dat pomocí tlačítka *Classify data*. Výsledek klasifikace se zobrazí pomocí matice záměn v pravé části tohoto panelu. Pokud je před klasifikací zaškrtnuto políčko *Upwind correction*, proběhne korekce výstupu sítě a to následujícím způsobem. Pokud se mezi dvěma stejně klasifikovanými epochami objeví epocha klasifikovaná odlišně, je tato epocha překlasifikována na stejnou spánkovou fázi jako její sousedící epochy. Políčko *Only chosen phases in data* umožní odstranění nezvolených spánkových fází z dat pro klasifikaci před jejím spuštěním.



Obr. 37 Klasifikační panel

Dalším klasifikátorem je již zmíněný k-NN klasifikátor, u kterého se v nastavení volí pouze parametr  $k$ . Postup vybrání dat a spánkových fází, které mají být klasifikovány, je shodný jako v předchozím případě. Opět dochází k zobrazení klasifikační úspěšnosti pomocí matice záměn. Posledním klasifikátorem, který se dá ve zmíněném kontextovém menu zvolit je lineární diskriminační analýza, jejíž postup klasifikace je totožný s k-NN klasifikátorem.

## 7 ZHODNOCENÍ VÝSLEDKŮ KLASIFIKACE

Pomocí tří klasifikátorů byla provedena automatická klasifikace spánkových fází za použití PSG signálů. Klasifikace byla realizována pro různé varianty učebních a testovacích množin, pro dvě varianty klasifikovaných fází a pro různá nastavení klasifikátorů. U dopředné neuronové sítě došlo k volbě počtu skrytých vrstev a počtu neuronů a u k-NN klasifikátoru k výběru počtu nejbližších sousedů.

Tab. 18 uvádí srovnání výsledků jednotlivých klasifikátorů při klasifikaci W, N3 a REM fáze. Jedná se o případ, kdy na pěti signálech dochází k učení a na šestém k samotné klasifikaci. Z tabulky lze vyčíst, že nejvyšší úspěšnosti u 4 z 6 klasifikovaných signálů dosáhla neuronová síť obsahující jednu skrytou vrstvu se 16 neurony. Zároveň neuronová síť s hodnotou 91,2 % dosáhla nejvyšší průměrné klasifikační úspěšnosti. Z výsledků také vyplývá, že jsme pomocí těchto klasifikátorů schopni klasifikovat zmíněné 3 fáze s úspěšností 90 – 98 %.

Tab. 18 Srovnání úspěšnosti klasifikátorů při klasifikaci W, N3 a REM fáze

Klasifikovaný signál	Úspěšnost [%]		
	Neuronová síť	k-NN	LDA
40	91,8	70,3	<b>92,8</b>
42	<b>90,8</b>	75,1	90,4
43	<b>90,3</b>	85,1	84,3
44	81,4	<b>91,8</b>	84,7
48	<b>95,0</b>	87,3	92,8
51	<b>97,8</b>	94,3	96,1
Průměrná hodnota	91,2	84,0	90,2

Pokud klasifikujeme všechny fáze W, N1-N3 a REM, nejvyšší úspěšnosti je opět dosaženo téměř u všech signálů pomocí neuronové sítě s 1 skrytou vrstvou se 6 neurony. Z tab. 19 je patrné, že se signál 44 se svojí hodnotou výrazně odlišuje od ostatních, avšak hodnoty jeho parametrů v porovnání s ostatními signály nejsou odlišné. Důvodem by však mohla být rozdílnost v počtu jednotlivých epoch ve srovnání s ostatními signály. Signál 44 má ze všech klasifikovaných signálů nejmenší počet epoch, na druhou stranu má nejvíce epoch ve fázi N1, a to celých 61,5 %. Jelikož je fáze N1 obtížně odlišitelná od ostatních fází, mohlo by to být zřejmý vliv. Stejně tomu je i u signálu 48, který vykazuje druhou nejnižší úspěšnost. Celkový počet jeho epoch dosahuje druhé nejvyšší hodnoty, naopak počet epoch ve fázi N1 druhé nejvyšší. Průměrná klasifikační úspěšnost neuronové sítě dosahuje hodnoty 62,1 %, nicméně zanedbáme-li signál 44, průměrná úspěšnost vzroste na 68,2 %. Srovnáme-li průměrné hodnoty při klasifikaci W, N3 a REM fáze a všech fází najednou, dochází k poklesu úspěšnosti přibližně o 30 %.

Tab. 19 Srovnání úspěšnosti klasifikátorů při klasifikaci všech fází

Klasifikovaný signál	Úspěšnost [%]		
	Neuronová síť	k-NN	LDA
40	<b>73,3</b>	61,6	71,5
42	<b>71,8</b>	65,7	67,3
43	<b>67,8</b>	62,7	57,9
44	29,3	33,7	<b>35,2</b>
48	<b>53,9</b>	49,8	51,1
51	<b>76,3</b>	65,7	67,6
Průměrná hodnota	62,1	56,5	58,4

Porovnáme-li předchozí výsledky s výsledky získané pomocí postupu, kdy ze šesti signálů je část dat náhodně vybrána k učení a část ke klasifikaci, je zřejmé, že došlo podle předpokladů ke zvýšení úspěšnosti. U klasifikace všech fází přibližně o 15 % a u klasifikace 3 fází průměrně o 6 %. Avšak tento postup není z pohledu klinické praxe vhodný. Jak vidíme z tab. 20, při klasifikaci W, N3 a REM fáze dosáhly stejné úspěšnosti klasifikátory pomocí neuronové sítě a také LDA. Hodnota klasifikace zde dosáhla 95 %. Při klasifikaci všech fází byl opět nejvíce úspěšný klasifikátor neuronové sítě. Z tabulky je také patrné, že při klasifikaci všech fází úspěšnost poklesla přibližně o 20 % ve srovnání s variantou, kdy jsou klasifikovány pouze fáze W, N3 a REM. Nutno také podotknout, že pro získání objektivnějšího statistického výsledku každá hodnota vznikla z deseti nezávislých učení a testování.

Tab. 20 Srovnání úspěšnosti klasifikátorů pomocí druhé varianty

Klasifikace	Úspěšnost [%]		
	Neuronová síť	k-NN	LDA
W, N3, REM	95,2	91,0	<b>95,3</b>
W, N1-N3, REM	<b>76,9</b>	71,1	72,5

Dosažené výsledky je vhodné porovnat s dostupnými údaji z literatury. Někteří autoři a jejich dosažené výsledky jsou uvedeny v tab. 2. Výsledky jsou závislé na vybraných klasifikačních příznacích, metodě klasifikace, zároveň na použitých signálech a jejich hodnocení. Výsledek dosažený při klasifikaci W, N3 a REM fáze je srovnatelný s výsledky dostupnými v odborné literatuře. Tento výsledek dosahuje u nejlepšího klasifikátoru průměrně přes 91 %. Při klasifikaci všech spánkových fází se klasifikační úspěšnost autorů odborných článků pohybuje v rozmezí 70 – 90 %. V našem případě bylo dosaženo úspěšnosti přes 70 % v polovině případů. Nicméně musíme vzít v úvahu, že námi použité signály byly naměřeny u pacientů trpících poruchami spánku, což se mohlo projevit na dosažených výsledcích.

## 8 ZÁVĚR

Tato diplomová práce se zabývá automatickou klasifikací spánkových fází na základě PSG signálů. První část je věnována literární rešerši, která je rozdělena na polysomnografii, extrakci příznaků a metody pro klasifikaci dat.

V praktické části je pomocí tří klasifikátorů, konkrétně dopředné neuronové sítě, k-NN klasifikátoru a lineární diskriminační analýzy, provedena samotná klasifikace PSG dat. Klasifikaci předcházela analýza založená na výpočtu vybraných příznaků v časové, frekvenční a časově-frekvenční oblasti z 30s epoch EEG, EMG a EOG signálů. Na základě statistické analýzy pomocí Kruskal-Wallisova testu a dopředného selekční algoritmu bylo vybráno 20 příznaků, které jsou základem zmíněné klasifikace. Analýze je věnovaná podstatná část práce, neboť výběr příznaků významně ovlivňuje celkovou přesnost klasifikace. Navržený klasifikační postup byl otestován na šesti signálech dostupných v databázi na ÚBMI. Na závěr je provedeno zhodnocení úspěšnosti klasifikace a výsledky porovnány s dostupnými údaji z literatury.

Při samotné klasifikaci byla testována různá nastavení a rozdělení učebních a testovacích množin. Nejvyšší úspěšnost byla dosažena pomocí neuronové sítě obsahující jednu skrytou vrstvu. Bylo zjištěno, že zvýšení počtu skrytých vrstev nevede ke zlepšení výsledku.

Klasifikace W, N3 a REM fáze byla vyhodnocena jako úspěšná, jelikož dosažená klasifikační úspěšnost byla srovnatelná s autory odborných publikací. Při klasifikaci všech fází byla u dvou signálů zaznamenána nižší úspěšnost. Tyto signály se vyznačovaly významně vyšším poměrným zastoupením N1 fáze v datech. N1 fáze je obtížně rozpoznatelná od ostatních fází.

Ke zlepšení klasifikační úspěšnosti může přispět přidání dalších klasifikačních příznaků, např. detekovat K-komplexy a spánková vřetena, která jsou typická pro N2 fázi. Bylo by vhodné ověřit vlivy dalších nastavení klasifikátorů, např. zvolit u neuronové sítě jinou metodu učení nebo jiné počty neuronů.

V programovém prostředí Matlab byl vytvořen program s grafickým uživatelským rozhraním, kde dochází k nahrání vybraných signálů, výpočtu parametrů, výběru vhodných parametrů pomocí dopředné selekce a samotné klasifikaci. Program slouží k ověření vlivu volby příznaků a nastavení klasifikátorů na úspěšnost klasifikace. Není možné načíst signál, u kterého předem není známo hodnocení odborníka.

## 9 LITERATURA

- [1] PHILIPS HEALTHCARE. *The Sleep Technician guide*. 2009.
- [2] NEVŠÍMALOVÁ, Soňa a Karel ŠONKA. *Poruchy spánku a bdění*. Praha: Maxdorf, 1997, 256 s. ISBN 80-858-0037-3.
- [3] NOVELLI, Luana, Raffaele FERRI a Oliviero BRUNI. Sleep classification according to AASM and Rechtschaffen and Kales: Effects on sleep scoring parameters of children and adolescents. *Journal of Sleep Research* [online]. 2010, roč. 19, č. 1 PART. 2, s. 238–247. ISSN 09621105. Dostupné z: doi:10.1111/j.1365-2869.2009.00785.x
- [4] ŠUŠMÁKOVÁ, K. Human Sleep and Sleep EEG. *Measurement Science Review*. 2004, roč. 4.
- [5] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje 1*. 1. vyd. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013, 411 s. ISBN 978-80-248-3107-7.
- [6] VOJTĚCH, Zdeněk. *EEG v epileptologii dospělých*. Vyd. 1. Praha: Grada, 2005, 680 s., [24] s. barev. obr. příl. ISBN 80-247-0690-3.
- [7] SÖRNMO, Leif a Pablo LAGUNA. *Bioelectrical signal processing in cardiac and neurological applications*. Burlington: Elsevier Academic Press, c2005, xiii, 668 s. ISBN 978-012-4375-529.
- [8] HAMIDA, Sana Tmar-Ben a Beena AHMED. Computer based sleep staging: Challenges for the future. *2013 7th IEEE GCC Conference and Exhibition, GCC 2013* [online]. 2013: 280-285 [cit. 2015-10-22]. DOI: 10.1109/IEEEGCC.2013.6705790. ISBN 10.1109/IEEEGCC.2013.6705790. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6705790>
- [9] KOZUMPLÍK, J.: *Analýza biologických signálů*, skripta předmětu Analýza biologických signálů. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2013.
- [10] ZOUBEK, Lukáš. Automatic classification of human sleep recordings combining artifact identification and relevant features selection [online]. 2008 [cit. 2015-11-22]. Université Joseph-Fourier - Grenoble.
- [11] VURAL, Cahir a Murat YILDIZ. Determination of Sleep Stage Separation Ability of Features Extracted from EEG Signals Using Principle Component Analysis. *Journal of Medical Systems*. 2010, vol. 34, issue 1, s. 83-89. DOI: 10.1007/s10916-008-9218-9. [cit. 2015-10-20] Dostupné z URL: <<http://link.springer.com/10.1007/s10916-008-9218-9>>

- [12] ZOUBEK, L. CHARBONNIER, S. LESECQ, S. BUGUET, A. CHAPOTOT, F. Feature selection for sleep/wake stages classification using data driven methods. *Biomedical Signal Processing and Control*. 2007, vol. 2, issue 3, s. 171-179. DOI: 10.1016/j.bspc.2007.05.005. [cit. 2015-10-20] Dostupné z URL: < <http://www.sciencedirect.com/science/article/pii/S1746809407000365> >
- [13] KHALIGHI, Sirvan, Teresa SOUSA, Gabriel PIRES a Urbano NUNES. Automatic sleep staging: A computer assisted approach for optimal combination of features and polysomnographic channels. *Expert Systems with Applications* [online]. 2013, s. 7046-7059. DOI: 10.1016/j.eswa.2013.06.023. [cit. 2015-10-20]. ISBN 10.1016/j.eswa.2013.06.023. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S095741741300403X>
- [14] KOZUMPLÍK, J.: *Zpracování biologických signálů. Přednáška*. Brno: VUT v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012.
- [15] KRAJČA, Vladimír a Jitka MOHYLOVÁ. *Číslíkové zpracování neurofyziologických signálů*. 1. vyd. V Praze: České vysoké učení technické, 2011, 168 s. ISBN 978-80-01-04721-7.
- [16] JAN, J.: *Číslíkové zpracování a analýza signálů: stručné skriptum*. 1. vyd. Brno: MJ servis Brno, s.r.o., 2005, 680 s. [24] barev. obr. příl. ISBN 978-80-214-4018-0.
- [17] JAN, J.: *Číslíková filtrace, analýza a restaurace signálů*. 2. vyd. Brno: VUTIUM, 2002, 427 s. ISBN 80-214-2911-9.
- [18] *Učebnice teorie rádiové komunikace*. [online]. [cit. 2015-11-10]. Dostupné z URL: <http://www.urel.feec.vutbr.cz/MTRK/?%DAvod>
- [19] ŠÍMA, Jiří a Roman NERUDA. *Teoretické otázky neuronových sítí*. Vyd. 1. Praha: MATFYZPRESS, 1996, 390 s. ISBN 80-858-6318-9.
- [20] KOZUMPLÍK, J.: *Umělá inteligence v medicíně*, skripta předmětu Umělá inteligence v medicíně. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2007.
- [21] HONZÍK, P.: *Strojové učení*, skripta předmětu Strojové učení. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2006.
- [22] MELOUN, Milan, Jiří MILITKÝ a Martin HILL. *Počítačová analýza vícerozměrných dat v příkladech*. Vyd. 1. Praha: Academia, 2005, 449 s. ISBN 80-200-1335-0.
- [23] MOTAMEDI-FAKHR, Shayan, Mohamed MOSHREFI-TORBATI, Martyn HILL, Catherine M. HILL a Paul R. WHITE. Signal processing techniques applied to human sleep EEG signals – A review. *Biomedical Signal*



- Processing and Control* [online]. 2014, roč. 10, s. 21–33 [cit. 2015-10-20]. DOI: 10.1016/j.bspc.2013.12.003. ISSN 17468094. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S174680941300178X>
- [24] *Matematická biologie* [online]. Brno: Institut biostatistiky a analýz Masarykovy univerzity [cit. 2015-11-22]. Dostupné z: <http://portal.matematickabiologie.cz/>
- [25] AGARWAL, R. a J. GOTMAN. Computer-assisted sleep staging. *IEEE Transactions on Biomedical Engineering* [online]. 2001, roč. 48, č. 12, s. 1412-1423 [cit. 2015-10-20]. DOI: 10.1109/10.966600. ISSN 00189294. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=966600>
- [26] BAKYTOVÁ, H., UGRON M. a O. KONŠTĚKOVÁ. *Základy štatistiky*. 1. vyd. Bratislava: Alfa, 1975.
- [27] PACHECO, O.R. a F. VAZ. Integrated system for analysis and automatic classification of sleep EEG. In: *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Vol.20 Biomedical Engineering Towards the Year 2000 and Beyond (Cat. No.98CH36286)* [online]. IEEE, 1998, roč. 20m č. 4, s. 2062-2065 [cit. 2015-10-20]. DOI: 10.1109/IEMBS.1998.747012. ISBN 0-7803-5164-9. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=747012>
- [28] SCHWAIBOLD, M.H., T. PENZEL, J. SCHOCHLIN a A. BOLZ. Combination of AI components for biosignal processing application to sleep stage recognition. In: *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [online]. IEEE, 2001, roč. 2, č. 2, s. 1692-1694 [cit. 2015-10-20]. DOI: 10.1109/IEMBS.2001.1020541. ISBN 0-7803-7211-5. Dostupné z: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1020541>
- [29] ÁLVAREZ-ESTÉVEZ, Diego, José M. FERNÁNDEZ-PASTORIZA, Elena HERNÁNDEZ-PEREIRA a Vicente MORET-BONILLO. A method for the automatic analysis of the sleep macrostructure in continuum. *Expert Systems with Applications* [online]. 2013, roč. 40, č. 5, s. 1796-1803 [cit. 2015-10-20]. DOI: 10.1016/j.eswa.2012.09.022. ISSN 09574174. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0957417412010767>
- [30] LIANG, Sheng-Fu, Chin-En KUO, Yu-Han HU a Yu-Shian CHENG. A rule-based automatic sleep staging method. *Journal of Neuroscience Methods* [online]. 2012, roč. 205, č. 1, s. 169-176 [cit. 2015-10-20]. DOI: 10.1016/j.jneumeth.2011.12.022. ISSN 01650270. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S016502701100759X>

- [31] TANG, W-C, S-W LU, C-M TSAI, C-Y KAO a H-H LEE. Harmonic Parameters with HHT and Wavelet Transform for Automatic Sleep Stages Scoring. *Proceedings of the World Academy of Science, Engineering and Technology* [online]. 2007, roč. 22, č. 7, s. 414–417. ISSN 1307-6884.
- [32] OROPESA, Edgar, Hans L. CYCON a Marc JOBERT. Sleep Stage Classification using Wavelet Transform and Neural Network [online]. 1999, č. 510. Dostupné z: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.45.6844&rep=rep1&type=pdf>
- [33] PAVLÍK, Tomáš a Ladislav DUŠEK. *Biostatistika*. Vyd. 1. Brno: Akademické nakladatelství CERM, 2012, 131 s. ISBN 978-80-7204-782-6.
- [34] SINGH, Mandeep, Mooninder SINGH a Surabhi GANGWAR. Feature Extraction from EEG for Emotion classification. *IJITKM* [online]. 2013, č. 1, s. 6-10 [cit. 2015-12-1]. Dostupné z: <http://csjournals.com/IJITKM/PDF%207-1/2.pdf>
- [35] Wavelet Toolbox. *MathWorks* [online]. Natick, Massachusetts, U.S.A., 2015 [cit. 2015-12-12]. Dostupné z: <http://www.mathworks.com/help/wavelet/index.html>
- [36] ŘEHÁKOVÁ, Blanka. Nebojte se logistické regrese. *Sociologický časopis: Metodologická rubrika* [online]. Sociologický ústav AV ČR, Praha, 2000, č. 4, s. 18 [cit. 2015-12-1]. Dostupné z: [http://sreview.soc.cas.cz/uploads/5f6961faa17dd98a67cfb71a5205469d297369f5\\_372\\_475REHAK.pdf](http://sreview.soc.cas.cz/uploads/5f6961faa17dd98a67cfb71a5205469d297369f5_372_475REHAK.pdf)
- [37] *Multivariate Methods* [online]. s. 54 [cit. 2015-12-13]. Dostupné z: [http://cda.psych.uiuc.edu/multivariate\\_fall\\_2012/matlab\\_help/multivariate\\_methods.pdf](http://cda.psych.uiuc.edu/multivariate_fall_2012/matlab_help/multivariate_methods.pdf)
- [38] VOLNÁ, Eva. *Neuronové sítě I* [online]. Vyd. 2. Ostrava: Ostravská univerzita v Ostravě, 2008, 86 s. [cit. 2015-12-29]. Dostupné z: [http://www1.osu.cz/~volna/Neuronove\\_site\\_skripta.pdf](http://www1.osu.cz/~volna/Neuronove_site_skripta.pdf)
- [39] HENRI, Gavin. The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems. *Department of Civil and Environmental Engineering, Duke University* [online]. 2016, 17 s. [cit. 2016-06-05]. Dostupné z: <http://people.duke.edu/~hpgavin/ce281/lm.pdf>


## 10 SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

PSG	Polysomnografie
EEG	Elektroencefalogram
EMG	Elektromyogram
EOG	Elektrookulogram
EKG	Elektrokardiogram
MT	Epocha pohybových artefaktů (z angl. movement time)
W	Bděllost (z angl. wake)
REM	Fáze spánku (z angl. rapid eye movement)
NREM	Fáze spánku (z angl. non rapid eye movement)
RαK	Rechtschaffen a Kales
AASM	Americká akademie spánkové medicíny (z angl. American Academy of Sleep Medicine)
Hz	Hertz
μV	Mikrovolt
MJ	Motorická jednotka
FT	Fourierova transformace (z angl. Fourier transform)
STFT	Krátkodobá Fourierova transformace (z angl. Short-time Fourier transform)
DFT	Diskrétní Fourierova transformace (z angl. Discrete Fourier transform)
PSD	Spektrální výkonová hustota (z angl. Power spectral density)
WT	Vlnková transformace (z angl. Wavelet transform)
CWT	Spojité vlnková transformace (z angl. Continuous Wavelet transform)
DWT	Diskrétní vlnková transformace (z angl. Discrete Wavelet transform)
IBL	Učení založené na instancích (z angl. Instance Based Learning)
k-NN	k-nejbližších sousedů (z angl. k-nearest neighbours)
LDA	Lineární diskriminační analýza (z angl. Linear discriminant analysis)
QDA	Kvadratická diskriminační analýza (z angl. Quadratic discriminant analysis)
RS	Rozhodovací stromy
SVM	Algoritmy podpůrných vektorů (z angl. Support Vector Machines)
ANOVA	Analýza rozptylu
GUI	Grafické uživatelské rozhraní (z angl. Graphic user interface)


# 11 PŘÍLOHY

## PŘÍLOHA A


Krabicové grafy 13 vybraných příznaků získaných v časové oblasti (obrázek 1 – obrázek 4), ve frekvenční oblasti (obrázek 5 – obrázek 7) a časově frekvenční oblasti (obrázek 8 - obrázek 13). Parametry jsou počítány pro jednotlivé spánkové fáze šesti náhodně vybraných signálů a pro vybrané PSG kanály (u EEG – kanál C4-M1, u EOG – kanál E1).




Obrázek 1 Krabicové grafy pro mobilitu jednotlivých spánkových fází a u EMG signálů




Obrázek 2 Krabicové grafy pro koeficient šikmosti jednotlivých spánkových fází a u EMG signálů




Obrázek 3 Krabicové grafy pro střední hodnotu jednotlivých spánkových fází a u EMG signálů




Obrázek 4 Krabicové grafy pro entropii jednotlivých spánkových fází a u EEG signálů




Obrázek 5 Krabicové grafy pro relativní výkonové spektrum theta pásma jednotlivých spánkových fází a u EEG signálů




Obrázek 6 Krabicové grafy pro relativní výkonové spektrum beta1 pásma jednotlivých spánkových fází a u EEG signálů



Obrázek 7 Krabicové grafy pro relativní výkonové spektrum beta2 pásma jednotlivých spánkových fází a u EEG signálů




Obrázek 8 Krabicové grafy pro poměr delta/theta pásma jednotlivých spánkových fází a u EEG signálů




Obrázek 9 Krabicové grafy pro relativní výkon delta pásma jednotlivých spánkových fází a u EEG signálů







Obrázek 10 Krabicové grafy pro relativní výkon theta pásma jednotlivých spánkových fází a u EEG signálů



Obrázek 11 Krabicové grafy pro relativní výkon alfa pásma jednotlivých spánkových fází a u EEG signálů



Obrázek 12 Krabicové grafy pro entropii koeficientů theta pásma/celkový výkon jednotlivých spánkových fází a u EEG signálů



Obrázek 13 Krabicové grafy pro entropii koeficientů alfa pásma/celkový výkon jednotlivých spánkových fází a u EEG signálů