



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. Tereza Kříženecká

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2017

Diplomová práce

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

Studentka: Bc. Tereza Kříženecká

ID: 155587

Ročník: 2

Akademický rok: 2016/17

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: 6.2.2017

Termín odevzdání: 19.5.2017

Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

Konzultant:

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 automatickou klasifikací polysomnografických záznamů, která je založená na analýze parametrů v časové a 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. Klasifikace je poté provedena pomocí metody SVM a zhodnocení úspěšnosti klasifikace je provedeno pomocí senzitivity, specificity a procentuální úspěšnosti. Práce byla provedena v programovém prostředí MATLAB.

Klíčová slova

Spánkové fáze, polysomnografie, analýza PSG dat, statistická analýza, automatická klasifikace, SVM, senzitivita, specificita

Abstract

The thesis is focused on automatic classification of polysomnographic signals based on various parameters in time and 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. Classification is performed using the SVM method and evaluation of the success of the classification is done using sensitivity, specificity and percentage success. Classification method was implemented using Matlab.

Keywords

Sleep stages, polysomnography, PSG data analysis, statistic analysis, automatic classification, SVM, sensitivity, specificity

Bibliografická citace:

KŘÍŽENECKÁ, T. *Automatická klasifikace spánkových fází z polysomnografických dat.*
Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních
technologií, 2017. 70 s. Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

Prohlášení

„Prohlašuji, že svou závěrečnou 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 závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma 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.

V Brně dne **19. května 2017**

.....
podpis autora

Poděkování

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

V Brně dne **19. května 2017**

.....
podpis autorky

Obsah

1.	ÚVOD	13
2.	POLYSOMNOGRAFIE	14
2.1	Hodnocení polysomnografického záznamu	14
2.2	Elektroencefalografie	17
2.2.1	Snímání EEG	17
2.2.2	Charakteristiky EEG záznamu	19
2.2.3	Frekvenční pásma	19
2.3	Elektrookulografie.....	20
2.3.1	Snímání EOG.....	20
2.3.2	Charakteristiky EOG záznamu	21
2.4	Elektromyografie.....	21
2.4.1	Snímání EMG	22
3.	AUTOMATICKÁ KLASIFIKACE SPÁNKOVÝCH FÁZÍ	23
3.1	Předzpracování	23
3.1.1	Artefakty	23
3.1.2	Filtrace	24
3.1.3	Segmentace	24
3.2	Analýza	24
3.2.1	Analýza v časové oblasti.....	24
3.2.2	Analýza ve frekvenční oblasti.....	26
3.2.3	Analýza v časově-frekvenční oblasti	27
3.2.4	Analýza pomocí nelineárních metod	29
3.3	Metody klasifikace	29
3.3.1	Neuronové sítě	29
3.3.2	Shluková analýza	30
3.3.3	K – nejbližších sousedů	31
3.3.4	Diskriminační analýza	31
3.3.5	Rozhodovací stromy	32
3.3.6	Metoda podpůrných vektorů (support vector machines, SVM)	32
3.3.7	Hodnocení úspěšnosti klasifikace	34
4.	ANALÝZA PSG SIGNÁLU ZE STUDIE RELIEF.....	36
4.1	Popis dat.....	36
4.2	Použité metody statistické analýzy	38
4.3	Analýza PSG dat v časové oblasti.....	39
4.4	Analýza ve frekvenční oblasti	43

4.5	Vybrané parametry.....	46
5.	KLASIFIKACE PSG SIGNÁLŮ	47
5.1	Klasifikace pomocí vybraných parametrů	47
5.2	Klasifikace pomocí EEG parametrů.....	49
5.3	Klasifikace pomocí všech parametrů ze signálů EEG, EOG a EMG.....	50
5.4	Klasifikace pomocí časových parametrů	52
5.5	Klasifikace pomocí frekvenčních parametrů	53
5.6	Zhodnocení úspěšnosti klasifikace.....	55
6.	ZÁVĚR	57
	Literatura.....	58
	Seznam symbolů, veličin a zkratk.....	61
	Seznam příloh	62

Seznam obrázků

Obr 1 Rozmístění elektrod na povrchu mozku [1]	18
Obr 2 Rozmístění elektrod pro snímání EOG [14]	21
Obr 3 Schéma biologického a formálního neuronu [23]	30
Obr 4 Rozmístění elektrod pro EEG ve studiu RELIEF	36
Obr 5 Rozmístění elektrod pro EOG ve studiu RELIEF	37
Obr 6 Rozmístění elektrod pro EMG ve studiu RELIEF	37
Obr 7 Ukázka hypnogramu	37
Obr 8 Příklad boxplotu	39
Obr 9 Aktivita EEG, EOG, EMG	40
Obr 10 Parametry vykazující statistický významný rozdíl mezi spánkovými fázemi	43
Obr 11 Výkon pásma alfa v jednotlivých spánkových fázích	44
Obr 12 Výkon pásma delta v jednotlivých spánkových fázích.....	44
Obr 13 Příklad křížové validace pro nfold=5	47
Obr 14 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	48
Obr 15 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	49
Obr 16 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	50
Obr 17 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	50
Obr 18 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	51
Obr 19 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	51
Obr 20 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	52
Obr 21 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	52
Obr 22 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	53
Obr 23 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	53
Obr 24 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat.....	54

Obr 25 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat..... 54

Seznam tabulek

Tab 1 Procentuální zastoupení fází spánku u dospělého člověka	16
Tab 2 Celkový počet 30s epoch jednotlivých fází	40
Tab 3 Příklad statistického testu	41
Tab 4 Vybrané parametry vypočítané z epoch jednotlivých spánkových fází vhodných pro automatickou klasifikaci podle analýzy v časové oblasti	42
Tab 5 Tabulka parametrů relativního výkonového spektra jednotlivých pásem v EEG spánkových fází vhodných a nevhodných pro automatickou klasifikaci.....	44
Tab 6 Tabulka spánkových fází vhodných a nevhodných pro automatickou klasifikaci u výkonových spekter EOG a EMG pro každého pacienta zvlášť	45
Tab 7 Tabulka spánkových fází vhodných a nevhodných pro automatickou klasifikaci podle výkonového spektra signálů EOG a EMG.....	46
Tab 8 Tabulka spánkových fází vhodných a nevhodných pro automatickou klasifikaci u maxim, minim a průměrů z výkonových spekter EEG, EOG a EMG.....	46
Tab 9 Parametry vybrané pro následnou klasifikaci.....	46
Tab 10 Se(senzitivita) a Sp(specificita) trénovacích a testovacích dat u vybraných parametrů pomocí časové a frekvenční analýzy, lineární SVM	55
Tab 11 Se(senzitivita) a Sp(specificita) trénovacích a testovacích dat u vybraných parametrů pomocí časové a frekvenční analýzy, radiální SVM	55

1. ÚVOD

V současné době přibývá počet lidí se spánkovými poruchami. Proto je stále více důležitá analýza a hodnocení polysomnografických záznamů. V současné době lékaři hodnotí záznamy vizuálně, což je problém, jelikož hodnocení je časově náročné a často může nastat subjektivní chyba v hodnocení. Z tohoto důvodu je snaha o zlepšení metod automatické klasifikace spánku. Tato diplomová práce se v první části zabývá polysomnografií, což je základní metoda, která se používá při vyšetření poruch spánku a bdění. Během této metody je nasnímáno několik signálů a parametrů. V práci bude použit pouze signál EEG, EOG a EMG.

V druhé části se zabývá automatickou klasifikací spánkových fází z polysomnografických záznamů, která je založená na výpočtu vybraných parametrů v časové a frekvenční oblasti. Parametry jsou počítány z 30s úseků jednotlivých spánkových fází elektroencefalografických (EEG), elektromyografických (EMG) a elektrookulografických (EOG) signálů snímaných v průběhu spánku. Pomocí statistické analýzy jsou vybrány parametry, které jsou vhodné pro následnou automatickou klasifikaci spánkových fází. Samotná analýza se provádí rozdělením na epochy, ve kterých se následně určují spánková stádia podle Rechtschaffen a Kales (R&K) a American Academy of Sleep Medicine (AASM) standardů. Pomocí statistické analýzy (KruskalWallisovým testem) jsou vybrány statistické parametry vhodné pro následnou automatickou klasifikaci. Pomocí vybraných parametrů bude následně provedena klasifikace. Klasifikace bude provedena pomocí metody SVM. Následně bude provedeno vyhodnocení správnosti klasifikace. Praktická část práce je realizovaná v programu MATLAB. Zde bylo provedeno porovnání hodnot různých parametrů vypočtených z EEG, EMG a EOG signálů nasnímaných v průběhu různých spánkových fází v rámci studie RELIEF, která byla poskytnuta z Fakultní nemocnice u Svaté Anny.

2. POLYSOMNOGRAFIE

Polysomnografické vyšetření (PSG) je základní metodou v diagnostice poruch spánku a sledování tělesných funkcí. Umožňuje rozlišení spánku a bdění, jednotlivé fáze spánku, dýchací poruchy ve spánku i příčiny probuzení ze spánku. Skládá se ze tří základních modalit[1]:

- EEG (elektroencefalografie)
- EOG (elektrookulografie)
- EMG (elektromyografie)

a z dalších souběžně zaznamenávaných tělesných aktivit:

- EKG (elektrokardiografie)
- EMG svalů a bérce
- saturace hemoglobinu kyslíkem
- poloha těla, obrazový záznam (video)
- dýchací zvuky, dýchací úsilí (pohyby břicha a hrudníku), proud vzduchu při dýchání

Pro snímání polysomnografického záznamu se používá standardně 14 kanálů [3]:

- 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.

Vyšetření se provádí ve spánkové laboratoři v průběhu celé noci. Pomocí vyšetření můžeme sestavit hypnogram (graf, který zobrazuje sled jednotlivých fází), ve kterém se posuzuje architektura spánku. Polysomnografie je indikována v případě důvodného klinického podezření na syndrom spánkové apnoe nebo pohybové spánkové poruchy.

2.1 Hodnocení polysomnografického záznamu

Při hodnocení záznamů hodnotíme spánková stádia po epochách. Epochy trvají 30 sekund. Jelikož hodnocení dat nebylo jednotné, zavedlo se skórování dat podle dvou standardů. První standard je tzv. manuál Rechtschaffen a Kales (R&K), který charakterizuje noční záznam a byl představen v roce 1968. Tento standard se používal 40 let a nyní se používá jen v několika státech. V ostatních se používá standard American Academy of Sleep Medicine (AASM), který se používá od roku 2007[7].

AASM standard

Pokud bychom porovnali standard AASM a R&K, zjistili bychom odlišnosti. Standard R&K je složen z

- MT
- W
- NREM (S1-S4)
- REM.

AASM se skládá z

- W
- N1
- N2
- N3
- REM.

Zde můžeme vidět, že AASM se skládá ze tří hlavních částí, a to z W, NREM a REM. NREM se dále dělí pouze do 3 fází, což usnadňuje práci. Při zavedení 4 fází docházelo k různému subjektivnímu hodnocení. Sjednocením dvou fází S3 a S4 do N3 došlo k zjednodušení a větší shodě mezi odborníky. NREM se tedy dělí na N1, N2, N3. R&K standard oproti tomu rozlišuje zvlášť pohybové artefakty a spánek. Oba standardy se hodnotí po epochách, což jsou 30 sekundové úseky, ve kterých se rozlišuje spánková fáze. Pokud by se stalo, že se v jedné epoše nachází dvě spánková stádia, epocha se označí tím stádiem, které je v epoše zastoupeno více [3], [7], [11]. Dále si popíšeme jednotlivé fáze u AASM standardu[3]:

• **Bdělost (W)**

Bdělost se dělí na relaxovanou a nerelaxovanou, přičemž nerelaxovaná se projevuje desynchronizací záznamu, vlnami beta o frekvenci 18 - 25 Hz a napětím 10 - 30 μ V. Relaxovaná bdělost se vyznačuje alfa vlnami o frekvenci 8-12 Hz a napětím 20 - 40 μ V. Dále beta vlnami a theta vlnami.

• **N1**

N1 můžeme poznat pomocí hojně se vyskytujících vln theta o frekvenci 4 - 7 Hz a amplitudě 50 - 70 μ V, ve většině epochy však nenajdeme alfa vlny. Fáze trvá 6 - 10 minut.

• **N2**

V N2 fázi se nachází theta vlny (4-7 Hz), spánková vřetena a K – komplexy. Spánková vřetena jsou vlny s rostoucí a klesající amplitudou o frekvenci 12 – 14 Hz, které trvají kolem 0,5 sekund. U dospělého jsou s frekvencí 3 – 8 vřeten za minutu, ve stáří frekvence klesá. Vřetena se obvykle objevují s K – komplexy, což jsou bifázické pomalé vlny, které trvají minimálně 0,5 sekund. Skládají se z vysoké pomalé ostré negativní vlny a pozitivní vlny s menší amplitudou. Frekvence výskytu je 1-3 za minutu. Časový odstup K – komplexů a spánkových vřeten musí být maximálně tři minuty. Během N2 spánku se oční bulby nepohybují. V EOG jde dobře rozlišit K-

komplexy a spánková vřetena, jelikož se jejich maximum nachází nad frontálním lalokem. V EMG uvidíme kontinuální tonickou svalovou aktivitu pouze s nižšími intenzitami.

- NREM3 (S3)

Fáze NREM3 se označuje jako fáze hlubokého spánku. Nejvíce jsou zde vidět vlny theta (2 a méně Hz), pomalé vlny delta a spánková vřetena s K-komplexy. Oční bulvy se nepohybují a svalová tonická aktivita nabývá nižších intenzit než ve fázi N2.

- REM

Ve fázi REM je spánek doprovázen rychlými očními pohyby. REM trvá zhruba 160 minut. U této fáze je charakteristické nízké napětí. Na EEG najdeme vlny theta, alfa a pilovité vlny s frekvencí 2 - 4 Hz. Nevyskytují se tu spánková vřetena a K-komplexy. EMG ukazuje krátké záškuby. Na EOG jsou viditelné nepatrné a rychlé oční pohyby všemi směry.

Architektura spánku

Spánek můžeme rozdělit na cyklicky se opakující úseky. Celý cyklus u dospělého člověka trvá 90 - 110 minut. Při usínání u člověka nastává nejdříve bdění, které později přejde do spánku, který začíná fází N1. Fáze N1 je lehký spánek, pro který jsou typické pomalé oční pohyby, klesá dechová a tepová frekvence, a také dochází k relaxaci svalů, mohou se však objevovat náhlé a rychlé svalové záškuby. Následně pokračuje spánek do fáze N2. N2 je také fáze lehkého spánku. V této fázi napětí pomalu klesá, oční bulvy se nepohybují a elektrická aktivita mozku se zpomaluje. Následuje fáze N3, která je brána za hluboký spánek. V této fázi se zpomaluje elektrická aktivita mozku a dochází k relaxaci kosterního svalstva. Cyklus se zakončuje REM fází, před kterou se ještě na chvíli objevují fáze N2, N1 nebo bdělost. Při REM fázi jsou typické rychlé pohyby očních bulbů a následné úplné uvolnění svalstva. Tento cyklus se během noci několikrát opakuje.

V prvním cyklu se nejvíce objevuje fáze N3, nejméně nebo vůbec pak REM fáze. V dalších cyklech spánku ubývá fáze N3 a přibývá fáze REM a N2. V Tab 1 vidíme procentuální zastoupení jednotlivých fází spánku u dospělého člověka [3]. Spánek se následně hodnotí podle tzv. hypnogramu, což je grafické zobrazení jednotlivých fází spánku během noci.

Tab 1 Procentuální zastoupení fází spánku u dospělého člověka

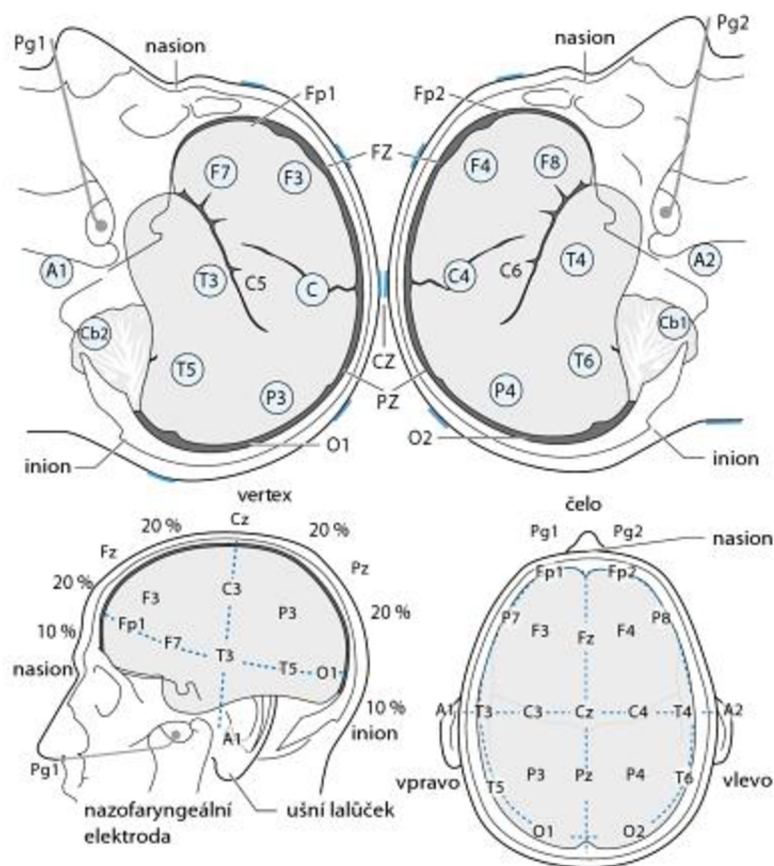
Bdělost	< 5%
N1	< 5%
N2	40 - 45 %
N3	20 - 25 %
REM	20 - 25 %

2.2 Elektroencefalografie

Elektroencefalografie je neurologická diagnostická metoda, která zaznamenává elektrickou aktivitu mozku. Nervové buňky mezi sebou komunikují pomocí nabitých iontů a díky jejich aktivitě vzniká elektrický potenciál. Tyto potenciály následně snímáme pomocí elektrod na povrchu hlavy (neinvazivní), nebo na povrchu mozkové kůry (invazivní). Signál snímáný na povrchu hlavy je slabý, řády mikrovoltů, díky průchodu signálu přes měkké tkáně a lebku. Vyšetření EEG se používá při podezření na epilepsii a poruchách spánku.

2.2.1 Snímání EEG

Signál EEG je součtem všech elektrických dějů snímáných elektrodou. Pro umístění elektrod na povrchu lebky se používá rozměřování, které vychází z definovaných výčnělků na lebce, a následném rozdělení všech vzdáleností po 10% a 20% - tedy systém „10 - 20“ [5]. Tento systém byl stanoven doktorem Herbertem Jasperem roku 1949 [6]. Tímto systémem je definováno umístění a názvy 19 základních elektrod. Snímání větším počtem elektrod umožňuje systém „10 - 10“. Maximálně se na lebce může použít 128 elektrod a to se využívá jen pro experimentální účely. Elektrody musí být nepolarizované. Tomu vyhovují vzácné kovy (zlacené elektrody), nebo se používají elektrody stříbrné s vrstvou AgCl v kombinaci s roztoky snižujícími přechodový odpor (gely, pasty). Elektrody se na lebku připevňují lepením pomocí kolodia nebo EEG pasty [5].



Obr 1 Rozmístění elektrod na povrchu mozku [1]

Na Obr 1 je znázorněno rozmístění EEG elektrod. Na schématu rozložení vidíme písmena a čísla. Čísla lichá se nacházejí na levé hemisféře, sudá na pravé hemisféře. Elektrody ve střední čáře se označují písmenem „z“ (zero), tedy Fz, Cz, Pz a Oz. Písmena dále označují rozmístění elektrod podle oblastí hlavy. Jsou to:

- Fp - frontopolární
- F - frontální
- P - parietální
- T - temporální
- O - okcipitální
- C - centrální

Při snímání EEG se registrují rozdíly elektrických potenciálů mezi dvěma elektrodami - vzniká EEG svod. Počet snímacích elektrod odpovídá množství záznamových kanálů a způsobu snímání. Bipolární zapojení představuje snímání mezi dvěma aktivními elektrodami, unipolární (referenční) zapojení mezi aktivní a referenční elektrodou, která bývá umístěna například na ušním lalůčku. Získané křivky odrážejí synchronní, rytmickou aktivitu velkého množství korových neuronů. Podkladem jsou rozdílné změny membránového napětí na dendritech a tělech neuronů, které jsou dány součtem excitačních a inhibičních postsynaptických potenciálů [8].

2.2.2 Charakteristiky EEG záznamu

Při hodnocení EEG záznamu popisujeme následující parametry [9], [10]:

- Frekvence:

Udává počet grafoelementů (vlnové tvary) za sekundu. Udává se v Hertzích. Podle frekvence se rozlišují frekvenční pásma (alfa, beta, theta a delta).

- Amplituda:

Udává výšku grafoelementů = výstupní voltáž. Udává se v mikrovoltech. Měří se technikou peak-to-peak. Rozdělujeme ji na nízkou ($< 20 \mu\text{V}$), střední ($20 - 50 \mu\text{V}$) a vysokou ($>50 \mu\text{V}$). Její přesné měření nemá téměř význam, protože je ovlivněné různými faktory.

- Tvar:

Též morfologie. Dělí se pravidelný a nepravidelný. Pravidelnost se určuje podle symetričnosti vzestupné a sestupné fáze. Další dělení je na mono-, bi-, tri- a polyfázické. Dělení je založeno na počtu protnutí myšlenou základní linií, kolem které se EEG křivka vyskytuje.

- Výskyt v prostoru:

Výskyt v prostoru, dělí se na regionální a fokální

- Výskyt v čase:

Dělí se na kontinuální, epizodický, periodický a paraxymální

- Symetrie:

Výskyt aktivit stejného charakteru nad homologními místy obou polovin hlavy, souvisí s amplitudou

- Reaktivita:

Na určitý podnět

- Distribuce:

Elektroda nebo elektrody, ve kterých je EEG nejlépe zachycen. Dělí se na generalizovanou, difúzní, laterizovanou, fokální a regionální

- Rytmicita:

Dělí se na opakování vln rytmické a arytmiické

- Perzistence:

Frekvence, se kterou se určitý EEG vzorec objevuje v delším úseku grafu.

2.2.3 Frekvenční pásma

Vlny tvořící signál EEG jsou sinusoidního tvaru a rozdělují se podle frekvence měřené mezi minimy nebo maximy do pásem označovaných řeckými písmeny alfa, beta, delta a theta. Normální jsou vlny alfa a beta, vlny nižších frekvencí vyskytující se častěji se považují za patologické. Dělení pásem:

- Alfa rytmus:

Tento rytmus se nachází v oblasti 8-13 Hz. Vyskytuje se u zdravých dospělých jedinců v bdělém stavu. Maximum se objevuje nad zadními kvadranty mozkových hemisfér. Nejlépe je tato aktivita viditelná při zavřených očích. Alfa rytmus je viditelný před usnutím.

- Beta rytmus:

Je aktivita, která se nachází v oblasti 13-30 Hz. Najdeme ji hlavně u zdravých dospělých jedinců v bdělém stavu nad frontálními laloky. Rytmus beta nám ukazuje soustředění, logické myšlení, pocity (hněv, neklid a strach).

- Delta rytmus:

Je to frekvence v oblasti 1-4 Hz. U dospělého jedince se fyziologicky objevuje jen při hlubokém NREM spánku, hypnóze a transu, v bdělém stavu je patologický. U novorozenců do čtyř měsíců je fyziologický.

- Theta rytmus:

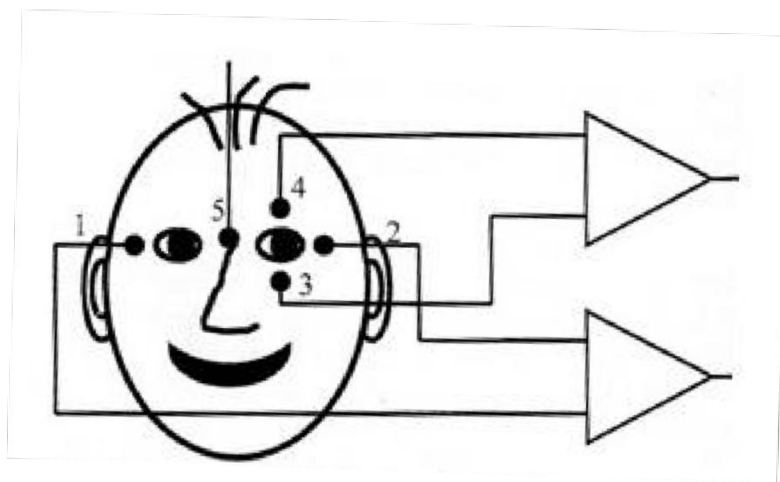
Nachází se v oblasti 4-8 Hz. U zdravého dospělého jedince je pouze v povrchních spánkových stádiích, v bdělém stavu je patologický. U dětí se vyskytuje normálně a fyziologický je i u dospělých při ospalosti [9].

2.3 Elektrookulografie

Elektrookulografie je diagnostická metoda snímající elektrickou aktivitu očí. Při EOG se využívá toho, že oční rohovka má kladný elektrický potenciál, zatím co sítnice má záporný elektrický potenciál. Díky tomuto jevu můžeme zjistit rozdíl potenciálů, který se mění při změně polohy oka. Změna polohy oka změní elektrostatické pole. Pro měření těchto změn používáme elektrookulograf. Velikost změn je snímána pomocí elektrod, které jsou umístěny na povrchu hlavy v okolí očí. Takto získaný záznam se nazývá elektrookulogram. Metoda se hojně využívá v lékařské diagnostice, jelikož je neinvazivní a měření je možné i při zavřených očích [12].

2.3.1 Snímání EOG

Na Obr 2 vidíme umístění elektrod při snímání EOG. Elektrody snímají velikost elektrostatického pole. Při snímání lze měřit horizontální i vertikální složku signálu. Pro měření horizontálního záznamu EOG jsou elektrody umístěny napravo a nalevo od oka (na Obr 2 elektrody 1. a 2.). Pro měření vertikální složky jsou elektrody nad a pod okem (na Obr 2 elektrody 3. a 4.) [13].



Obr 2 Rozmístění elektrod pro snímání EOG [14]

Jak bylo zmíněno výše, máme dvě základní zapojení elektrod – unipolární a bipolární. V případě EOG je při unipolárním snímání měřící elektrodou elektroda 1, 2, 3, 4. Tyto elektrody jsou maloplošné a jsou umístěny v elektricky aktivní oblasti. Referenční elektrodou je elektroda 5. Velkoplošná referenční elektroda je umístěna v elektricky neaktivní oblasti (nejčastěji uprostřed čela, na ušním lalůčku nebo na krku). U bipolárního zapojení jsou obě elektrody maloplošné a jsou umístěny v elektricky aktivní oblasti, kde snímají elektrický potenciál.

2.3.2 Charakteristiky EOG záznamu

Časový průběh EOG signálu nelze popsat matematickým vztahem. Řadí se tedy do signálů náhodných. Můžeme ho popsat jen pomocí charakteristik v časové a frekvenční oblasti. Amplituda signálu se pohybuje v rozmezí μV až mV . Při natočení oka o 1° v příslušném směru můžeme vidět v signálu změnu amplitudy až o $20 \mu\text{V}$. Frekvenční rozsah je $0,1 - 30 \text{ Hz}$ a má významnou stejnosměrnou složku.

2.4 Elektromyografie

EMG (elektromyografie) je diagnostická metoda, která snímá bioelektrické signály vznikající činností kosterního svalstva. Snímání signálu může být invazivní a neinvazivní. V PSG se využívá pouze neinvazivní snímání. Snímání a zpracování elektromyografického signálu není dodnes zcela standardizováno. Existují však mnohá doporučení, díky kterým se používají různé konfigurace, které se liší počtem použitých elektrod a uspořádáním těchto elektrod. Základní funkční jednotkou svalového aparátu je motorická jednotka. 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 – ty se větví). Každá z větví axonu je zakončena nervosvalovou

ploténkou, která inervuje dané svalové vlákno. Motoneuronem se šíří akční potenciál, který se na svalová vlákna přenáší pomocí nervosvalové ploténky. Díky tomu se uvolňuje neurotransmitter, který dráždí membránu vlákna a tím způsobí jeho depolarizaci. Akční potenciál se dále šíří a díky tomu dochází ke stahu svalového vlákna. Díky elektrickým potenciálům v membránách svalového vlákna vzniká elektrické pole. Měřením potenciálů elektrického pole získáme elektromyogram.

2.4.1 Snímání EMG

Při neinvazivním, tedy povrchovém snímání zaznamenáváme signál, který vzniká činností velkého množství motorických jednotek. Velikost amplitudy signálu je 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. Hlavní část výkonového spektra leží mezi 50 – 150 Hz. Při PSG je snímán pouze signál samovolných pohybů brady (3 elektrody – referenční ve středu brady a dvě elektrody 2 cm pod bradou a 2 cm napravo/nalevo od středové linie) a signál z dolní části nohou. (2 elektrody – na předním holenním svalu každé nohy) [15].

3. AUTOMATICKÁ KLASIFIKACE SPÁNKOVÝCH FÁZÍ

Automatickou detekci spánkových fází z polysomnografického vyšetření můžeme rozdělit na tři části a to na předzpracování, analýzu a klasifikaci dat.

3.1 Předzpracování

Předzpracování je prvním krokem úpravy dat. Úkolem předzpracování je odstranění veškerých nežádoucích složek (šum, artefakty), které jsou přítomny v záznamech, nebo naopak zvýraznění užitečných složek. Nejčastěji se v předzpracování používá filtrace.

3.1.1 Artefakty

Artefakty dělíme na chyby technické a chyby biologické.

- Artefakty technické

Mezi artefakty technické můžeme zařadit chyby elektrod a chyby způsobené přívodními vodiči elektrod. Artefakty vznikají díky pohybu elektrod, vzájemným pohybem přívodních vodičů elektrod nebo kvůli špatné elektrodě (kolísání nulové izolinie). Dále může být chyba způsobena špatným umístěním elektrod. Dále mohou být chyby v přenosových kabelech. Chyby vnějšího rušení jsou artefakty způsobené okolím pacienta a přístroje. Jsou to například chyby způsobené elektromagnetickým polem. Nejčastěji jsou to chyby způsobené impedancemi elektrod, kde se indukují různá napětí. Indiference je poté smíšena s biologickými signály a zesílena. Další artefakty mohou vznikat díky střídavému elektrickému proudu (50 Hz). Jsou to například zvonění telefonů, upozornění počítačů, jiné signalizace, upozornění a změna stavu osvětlení.

- Artefakty biologické

- Pohybové:

Při chybách způsobených pohybem se chyby ukazují na všech referenčních elektrodách.

- Svalové:

Jsou to většinou artefakty, které trvají krátce, mají ostrý tvar. Největší výskyt je díky svalový stahům – záškubům. Proto je potřeba, aby byl pacient co nejvíce relaxován.

- Oční:

Oční artefakty vznikají díky pohybům očí, mrkání, slzení, třesení víček, apod.

- Způsobené pocením:

Vznikají změnou kožního odporu, který vzniká při změně elektrického potenciálu kůže.

- Způsobené srdeční činností:

Tyto chyby vznikají u pacientů obézních (jelikož mají vyšší srdeční činnost, často mívají onemocnění kardiovaskulárního systému a vyšší tlak i tep, což způsobuje vyšší

srdeční činnost, která způsobuje rušení signálu), pacientů s malým krkem, nebo pokud jsou elektrody umístěny v blízkosti lalůček.

- Způsobené ORL činnostmi:

Jsou to chyby způsobené žvýkáním, mluvením, kašlem a polykáním.

- Způsobené tepovou činností:

Jsou způsobeny špatným umístěním elektrod v okolí cév.

3.1.2 Filtrace

Filtrace je první úpravou signálu před začátkem zpracování. Slouží k potlačení veškerých složek, které vnímáme jako rušivé. Jelikož pracujeme s biologickým signálem, musíme potlačit například síťové rušení o frekvenci 50 Hz, pocení pacienta, svalové artefakty, složky vznikající kvůli nepřesnému signálu z elektrod. Filtry musí být navrženy tak, aby byly z výpočetního hlediska kvalitní a zároveň rychlé. Pro filtraci používáme číslicové filtry, které dělíme podle délky impulzní odezvy (konečná a nekonečná odezva) a podle struktury (rekurzivní a nerekurzivní). U filtrace biologického signálu se nejčastěji používá FIR filtr [21].

3.1.3 Segmentace

Segmentace je dalším typem předzpracování, v němž se signál rozdělí na kratší úseky, které považujeme za stacionární. Slouží k odstranění artefaktů a následné analýze signálu. Segmentaci dělíme na adaptivní a konstantní, ve které se používá konstantní délka segmentů, díky níž mají segmenty stejnou délku a stejný počet vzorků. Výhodou konstantní segmentace je jednoduché použití a nízká výpočetní náročnost, výhodou adaptivní segmentace je proměnlivost délky segmentu. Délka segmentů se mění podle charakteristiky a přizpůsobuje se okamžitému stavu signálu. Výsledný signál je rozdělený na segmenty s podobnými vlastnostmi.

3.2 Analýza

Účelem analýzy náhodných signálů v časové oblasti je najít vazby nebo zjistit neexistenci takových vazeb mezi hodnotami signálu v různých časových okamžicích. Pomocí různých metod můžeme využít potřebné informace ze signálu. Díky těmto metodám můžeme určit parametry signálů, které nám pomohou k automatické detekci spánkových stádií. Analýzu dělíme na časovou, frekvenční, časově - frekvenční a nelineární.

3.2.1 Analýza v časové oblasti

Analýzou bioelektrických signálů v časové oblasti můžeme reprezentovat elektrickou aktivitu a závislosti na čase. Účelem analýzy je najít vazby, popřípadě zjistit existenci

vazeb, mezi hodnotami signálu v různých časových okamžicích. Pro popis analýzy EMG, EEG a EOG používáme různé veličiny, jsou to [17], [18], [19]:

Střední hodnota

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad (3.1)$$

kde n je počet vzorků x_i měřeného signálu x v epoše.

Směrodatná odchylka

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.2)$$

Koeficient špičatosti - charakterizuje rozdělení náhodné veličiny, určuje relativní strmost nebo plochost rozdělení náhodné veličiny v porovnání s normálním rozdělením. Při normálním rozložení dostaneme hodnotu 3. Při rozdělení s více odlehlými hodnotami je špičatost vyšší než 3.

$$kurtosis = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{s^4} - 3 \quad (3.3)$$

Koeficient šikmosti - je charakteristickým rozdělením pravděpodobnosti náhodné veličiny. Nulová šikmost naznačuje, že náhodné veličiny jsou rovnoměrně rozděleny vlevo a vpravo od střední hodnoty. Kladná šikmost ukazuje, že vpravo od průměru se vyskytují odlehlejší hodnoty než vlevo od průměru. U záporné šikmosti je tomu přesně naopak.

$$skewness = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{s^3} \quad (3.4)$$

75. Percentil – je hodnota, pod kterou je umístěno 75 % hodnot náhodné proměnné. Někdy je také nazýván jako horní kvartil nebo třetí kvartil.

$$card\{x(i)/x(i) < \text{prctile}75\} = \frac{75 \cdot n}{100} \quad (3.5)$$

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

Entropie - je statistickou mírou neuspořádanosti, která je počítána z histogramu signálu během jedné epochy:

$$entr = - \sum_{j=1}^N \frac{n_j}{n} \ln \frac{n_j}{n} \quad (3.6)$$

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.

Dále pro analýzu používáme **Hjorthovy deskriptory** mezi něž patří aktivita, mobilita a složitost, které jsou vypočítány ze signálu pomocí první a druhé derivace a rozptylu.

Aktivita je definována jako rozptyl signálu, mobilita udává odhad střední frekvence signálu. Složitost je odhadem šířky pásma signálu [20].

Aktivita

$$A = \text{var}(x) = \frac{1}{n-1} \sum_{i=1}^n (x_i - x)^2 \quad (3.7)$$

Mobilita

$$M = \sqrt{\text{var}(x') \text{var}(x)} \quad (3.8)$$

Složitost

$$C = \frac{M(x')}{M(x)} = \sqrt{\frac{\text{var}(x'') \cdot \text{var}(x)}{\text{var}(x')^2}}, \quad (3.9)$$

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

3.2.2 Analýza ve frekvenční oblasti

Spektrální analýza nám umožňuje určit spektrum a spektrální výkonovou hustotu signálu. Matematicky se spektrální analýza udělá pomocí ortogonální transformace, kde je časovému průběhu přiřazeno spektrum a spektru signál [17].

Fourierova transformace

Fourierova transformace (FT) se používá pro převod signálu z časové osy do frekvenční oblasti a zpět. FT nám určuje spektrum spojitého signálu se spojitým časem. FT je vyjádřena pomocí vztahu [17]:

$$F(\omega) = F\{f(t)\} = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt, \quad (3.10)$$

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

Frekvenční analýza signálu nám určuje zastoupení jednotlivých frekvencí ve spektru signálu. FT vyjadřuje obraz signálu pomocí ortogonálních bázevých funkcí. Transformace pomocí integrálu ukáže signál v prostoru s bází ve formě harmonických funkcí. Díky tomu můžeme získat popis signálu jako závislost amplitudy a fáze na frekvenci.

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

$$DFT\{f_n\} = \left\{ F_k \sum_{n=0}^{N-1} f_n e^{-jk\Omega nT} \right\}, \quad (3.11)$$

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

Odhad spektra metodou periodogramu

Je to nejjednodušší způsob pro zjištění výkonového spektra pro spektrální analýzu. Určujeme ho jako střední hodnotu kvadrátů spekter jednotlivých realizací

$$S_{xx}(k) = E\left\{\frac{1}{N} X_w(k) X_w^*(k)\right\} = E\left\{\frac{1}{N} |X_w(k)|^2\right\} \approx \frac{1}{M} \sum_{w=w_1}^{w_M} |X_w(k)|^2, \quad (3.12)$$

kde X_w je M spekter realizace, každá o délce N . Z nich určíme výkonové spektrum $|X_w(k)|^2$ a ten potom zprůměrujeme.

Výkonové spektrum je funkce deterministická, ale fázové spektrum každé realizace je náhodné, proto nemá smysl je průměrovat. Průměrováním tedy snižujeme rozptyl odhadu výkonového spektra. Jestliže je signál ergodický, jeho výkonové spektrum lze odhadnout pouze z jedné realizace. To se dělá tak, že je signál délky N rozdělen na M úseků, které mají délku $N=N'/M$. Z každého takového úseku je poté vypočítáno spektrum a výsledky jsou zprůměrovány. Tímto způsobem dojde ke zmenšení rozlišovací schopnosti, protože pro výpočet jednotlivých spekter používáme menší počet vzorků, než má celý měřený signál. Proto se před výpočtem používá váhování některým z oken, aby se zmenšilo prosakování [21], [22].

Odhad spektra metodou korelogramu

Pro výpočet výkonového spektra se používá Wiener-Chinčinův teorém. Ten dává do souvislosti korelační funkci náhodného procesu $r_{xx}(\tau)$ s jeho výkonovým spektrem $S_{xx}(k)$ [21]:

$$S_{xx}(k) = DFT\{R_{xx}(\tau)\} = \sum_{\tau=-N+1}^{N-1} r_{xx}(\tau) e^{-j\omega\tau}, \quad (3.13)$$

kde $r_{xx}(\tau)$ je funkce deterministická a symetrická kolem středu.

Výkonové spektrum je také funkce deterministická, reálná. Pro ergodické procesy počítáme autokorelační funkci z jedné změřené realizace. Výpočet v sobě zahrnuje průměrování a výsledné spektrum má tedy menší rozptyl. Odhad autokorelační funkce je pro velké hodnoty τ hodně nepřesný, protože do průměru vstupuje málo hodnot. Proto se před výpočtem výkonového spektra provádí odříznutí několika posledních hodnot $r_{xx}(\tau)$ [21].

3.2.3 Analýza v časově-frekvenční oblasti

Analýza EEG v časově-frekvenční oblasti je výhodná, kromě jednotlivých frekvenčních složek získáme i informaci o jejich výskytu v čase. Analýzu v časově-frekvenční oblasti provádíme pomocí krátkodobé Fourierovy transformace a vlnkové transformace.

Krátkodobá Fourierova transformace

Krátkodobá FT, neboli STFT, je modifikace FT, která se používá k rozdělení signálu na krátké úseky, ze kterých jsou odvozena dílčí spektra. Úseky signálu jsou vymezené postupně se posouvajícím oknem dané délky. Na každém úseku, kde se předpokládá dostatečná stacionarita, je provedena FT. Frekvenční koeficienty Fourierovy řady jsou

periodické v ω s periodou ω_z . ω představuje úhlovou frekvenci, ω_z znamená úhlovou frekvenci, odpovídající vzorkovací frekvenci. Zpracovávaný signál má konečný počet hodnot. Zpracovávají se tedy konečné číselné posloupnosti a i frekvenční spektrum má konečný počet vzorků. V oblasti času i frekvence mají signály stejný počet vzorků N a při výpočtech přímé i zpětné transformace je považujeme za periodické, protože pracujeme s periodicky prodlouženými signály ze základního intervalu. DFT je přechodem mezi diskretním časovým signálem f_n a diskretním frekvenčním signálem F_k . DFT je definována vztahem [18], [19]:

$$DFT\{f_n\} = \left\{ F_k \sum_{n=0}^{N-1} f_n e^{-jk\Omega_n T} \right\}, \quad (3.14)$$

Pro výpočet samotné STFT se používá vztah [18], [19]:

$$STFT(\tau, f) = \int_{-\infty}^{\infty} [x(t) \cdot w^*(t - \tau)] \cdot e^{-j2\pi ft} dt, \quad (3.15)$$

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

Časová okna se mohou při přesouvání překrývat, to umožňuje plynulejší sledování vývoje spektra v čase. Délka okna se volí kompromisem. Krátkodobá spektra se sestavují do tzv. spektrogramů, souborů krátkodobých DFT spekter, které zachycují spektrální vývoj v čase jako 2D obraz. Na vodorovné ose je vynesena frekvence, na svislé ose časový vývoj a barva či úroveň jasu odpovídá amplitudě.

Vlnková transformace

Vlnková transformace je prostředek časově-frekvenční analýzy, který se používá jako časově-frekvenční popis signálu. Vlnková transformace, neboli WT (wavelet transform), je základním matematickým prostředkem pro analýzu nestacionárních signálů. Odstraňuje nevýhodu všech metod časově-frekvenční analýzy založených na FT, které používají harmonických, časově neomezených, bázových funkcí. Při FT je zapotřebí velký počet harmonických složek pro vyjádření strmých přechodů v čase. Naproti tomu, bázovými funkcemi WT jsou časově omezené průběhy, tzv. vlnky, generované časovou dilatací z jediného vzorku. Hodnoty spektra u WT jsou ovlivněny daným úsekem analyzovaného signálu, což je základní vlastností WT. Celý rozsah analyzovaného signálu pokrývají vlnky s nenulovými hodnotami po částech [17], [21]. WT se dělí na spojitou a diskretní. Pro spojitou platí vztah:

$$S_{CWT}(a, b) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt, \quad (3.16)$$

kde $x(t)$ je analyzovaný signál, a je dilatace (měřítko) mateřské vlnky ψ a b je časový posun.

Tvar vlnky závisí na parametrech a a b . Parametr a udává časovou dilataci funkce, změna časového posunu b umožňuje postupné pokrytí pomocí vlnek celý rozsah signálu [17].

3.2.4 Analýza pomocí nelineárních metod


Analýza pomocí nelineárních metod je založená na zásadách nelineární dynamiky a teorii chaosu. Podle této teorie jsou biologické signály výsledkem chaotických procesů. Proto mohou být tyto signály reprezentovány chaotickými parametry, do kterých zařazujeme Lyapunovy a Hurstovy exponenty, dimenzionální komplexnosti, entropie, fraktální dimenze, korelační dimenze. Některé studie ukazují, že jsou hodnoty chaotických parametrů závislé na spánkových fázích. Mohou být tedy použity jako jejich charakteristické vzorce. Teorie deterministického chaosu je založena na nelineární dynamice. Nejvíce používaná je korelační dimenze, která umožňuje detekovat vzájemné nelineární spojení mezi komplexními systémy a je schopná kvantifikovat sílu a směr této dynamické závislosti [18].

3.3 Metody klasifikace

Klasifikací dat se rozumí rozdělení daných objektů do tříd. Níže jsou popsány základní klasifikátory nejčastěji používané pro klasifikaci PSG dat.

3.3.1 Neuronové sítě

Základní jednotkou neuronové sítě je neuron, který byl navržen dle předlohy biologického neuronu. Stejně jako biologický neuron má umělý neuron několik vstupů a jeden výstup. U biologického neuronu označujeme vstupy jako dendrity. Vstupy u umělého neuronu jsou ohodnoceny synaptickými váhami, které určují její propustnost. Vážená suma vstupních hodnot vyjadřuje vnitřní potenciál neuronu. Hodnota potenciálu po dosažení prahové hodnoty indikuje výstup neuronu, který modeluje elektrický impuls axonu. Níže vidíme (viz. Obr 3) porovnání biologického a umělého neuronu [23],[37],[38].



Obr 3 Schéma biologického a formálního neuronu [23]

Umělá neuronová síť je složena ze vzájemně propojených formálních neuronů. Výstup z jednoho neuronu je vstupem pro jeden a více dalších neuronů. Architektura neuronové sítě je dána počtem a propojením neuronů. Neuronové sítě dělíme na neuronové sítě s učitelem a neuronové sítě bez učitele. Při učení s učitelem dochází nejprve k inicializaci vah a prahu, poté je předložena tréninková dvojice (vstup a tomu odpovídající výstup). Poté se vypočítá výstup, který se porovná s hodnotou požadovaného výstupu. Podle zjištěné odchylky se upravují váhy. Učení je rozděleno do epoch, ve kterých dochází k ukázaní všech učebních dvojic neuronové sítě. Pokud neskončila epocha učení, postup se opakuje, jinak se učení ukončí. Dále se v každé epoše vyhodnotí klasifikace a ukončí se učení, nebo se začne další epocha. Síť s učitelem se snaží napodobit předkládané vzory a učí se z příkladů. U druhého typu, učení bez učitele, obsahuje tréninková množina pouze vstupy sítě, síť si sama organizuje tréninkové vzory a zajišťuje jejich souborné vlastnosti. Po naučení neuronové sítě u obou případů nastává fáze vybavování, kdy neuronové síti předkládáme neznámý vzor, který nám neuronová síť zařadí do příslušné třídy [23],[27],[37],[38].

3.3.2 Shluková analýza

Shluková analýza je příznakově orientovaná metoda, při které dojde k seskupování zkoumaných objektů do skupin na základě jejich podobnosti resp. rozdílnosti. U shlukové analýzy se provádí učení bez učitele, které nemá žádnou apriorní informaci o objektech. Objekty jsou popsány n -rozměrnými příznaky, pomocí nichž shluková metoda klasifikuje objekty do jednotlivých tříd (shluků) tak, aby objekty, které patří do

stejného shluku, byly vzájemně podobné a zároveň nebyly příliš podobné s objekty mimo tento shluk [22].

Shlukování dělíme dále na hierarchické, jež má více možných řešení a k jehož interpretaci využíváme dendrogramů a na nehierarchické, které nabízí rozklad na n -shluků. Hierarchické shlukování se v poslední řadě dělí na aglomerativní, přičemž využíváme jednotlivých objektů a ty spojujeme do shluků, a na divizní, kdy vycházíme z jednoho shluku jako celku a ten dále dělíme do shluků menších [23].

Nejčastěji používaným algoritmem je k -means, který je složen z nejčastěji náhodně vybraných inicializačních shluků, do kterých se podle nejbližšího těžiště (centroidu) přemisťují objekty. Poté se přepočítají jednotlivé centroidy shluků do doby, kdy se složení shluků dále nemění.

Tímto způsobem se objekty přesouvají tak, aby variabilita uvnitř skupin byla co nejmenší a naopak variabilita mezi skupinami co největší [22].

3.3.3 K – nejbližších sousedů

Metoda k -NN (angl. k -nearest neighbours) patří mezi metody založené na instancích, které patří mezi jednoduché, ale účinné nástroje strojového učení. Algoritmus funguje na základě podobnosti objektu nového s objekty známými. Algoritmus se zařazuje mezi učení s učitelem a bez učitele. U samotného k -NN k žádnému učení nedochází. Učení je zde zastoupeno uložením 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 soused, 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 soused 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 [22],[27].

3.3.4 Diskriminační analýza

Diskriminační analýza je klasifikační metoda vícerozměrné statistické analýzy, pomocí níž subjekt přiřadí do existující třídy. Vstupní data jsou parametrické nebo neparametrické. Neparametrická třída znamená, že nemáme rozdělení náhodného

vektoru, který charakterizuje objekty. Parametrická metoda má náhodný vektor s konkrétním rozdělením.

Při klasifikaci objektů se na základě výstupů konstruuje predikce založená na skupině znaků, což jsou vstupní data. Nástrojem jsou použita trénovací data, kdy je pro každý objekt určen výstup a hodnota znaků. Pomocí těchto dat je sestaven predikční model, který umožňuje předpovědět výstup nového objektu. Predikční model se učí na základě trénovacích dat, proto můžeme říct, že se jedná o učení s učitelem. Nový objekt je poté zařazen do jedné z existujících tříd pomocí jeho znaků. Porovnávány jsou znaky tříd se znaky ostatních objektů. Daný objekt je zařazen do tříd pomocí míry podobnosti.

Pokud bychom neměli diskriminační analýzu, nové objekty by se zařazovaly do tříd pomocí apriorní pravděpodobnosti, ne však pomocí znaků objektu. Třídy jsou charakterizovány funkcí hustoty pravděpodobnosti náhodné veličiny.

Diskriminační analýzu můžeme dělit na lineární a kvadratickou. O lineární diskriminační analýzu se jedná v případě, kdy se hustoty jednotlivých tříd liší středními hodnotami. U kvadratické diskriminační analýzy se liší střední hodnota a kovariační matice [28].

3.3.5 Rozhodovací stromy

Metoda rozhodovacích stromů je nehierarchická a nelineární, umožňuje uložení znalostí. Znalosti můžeme ze struktury rozhodovacích stromů extrahovat nebo použít k analýze nových dat. Rozhodující stromy umí automaticky vytvářet algoritmy. Poté lze z jejich struktury pomocí srozumitelných grafických výstupů interpretovat získané znalosti. Rozhodovací stromy lze převádět do jazykových pravidel.

Abychom mohli vytvořit rozhodovací strom, musíme si nejprve připravit data, která se mají analyzovat. Množina dat je složena z jednotlivých prvků. Při vytváření rozhodovacího stromu do každého uzlu vstupují trénovací data. Pokud jsou splněny ukončovací podmínky, dojde ke konečné klasifikaci a z uzlu se stává list. Pokud není ukončovací podmínka splněna, tak musíme stanovit takovou podmínku, díky které budou data rozdělena do uzlů tak, abychom dosáhli co největšího informačního zisku.

Algoritmu rozhodovacích stromů existuje několik druhů, které se liší topologií, typem vstupních nebo výstupních proměnných. Jeden strom může být generován různými algoritmy [27].

3.3.6 Metoda podpůrných vektorů (support vector machines, SVM)

Algoritmy podpůrných vektorů se řadí do metod strojového učení, které jsou schopné oddělit nelineárně ohraničená data pomocí lineární funkce. Základní princip je převod původního dvourozměrného prostoru do vícedimenzionálního, kde jsme schopni oddělit jednotlivé třídy lineárně. Pomocí algoritmu hledáme nadrovinu, která v prostoru

příznaků rozděluje optimálně trénovací data. Datům, které leží nejbližší této nadrovině, říkáme podpůrné vektory [29].

SVM tvoří určitou kategorii tzv. jádrových algoritmů. Metoda se snaží využít výhody efektivních algoritmů pro nalezení lineární hranice a zároveň je schopna reprezentovat vysoce složité nelineární funkce. Pokud máme dvourozměrný prostor, máme tedy dvě třídy, které jsou odděleny nelineárně, řešením je přidání další dimenze. Problémem poté je, kam umístit lineární hranici tak, aby byla vedena co nejefektivněji z hlediska kategorizace budoucích dat, která nebylo při tréninku možno použít. Při mapování do prostoru s dostatečným počtem dimenzí lze nakonec vždy najít lineární oddělovač (nadrovinu). Obecně platí, že N datových bodů je možno vždy lineárně oddělit v prostoru s $N-1$ nebo více dimenzemi. Řešení je komplikováno faktem, že v d -rozměrném prostoru je lineární oddělovač definován rovnicí, která má d parametrů, takže hrozí, že dojde ke ztrátě obecnosti klasifikátoru tzv. přetrénováním. Proto se metoda snaží najít optimální lineární oddělovač, který poskytne co nejširší pásmo mezi ním a pozitivními příklady na jedné straně a negativními na druhé. Optimální lineární oddělovač se hledá pomocí metody kvadratického programování. Předpokládáme, že jsou přítomny klady x_i s klasifikací $y_i = \pm 1$ a cílem je najít optimální oddělovač. Problém jde převést na hledání hodnot parametrů α_i , které maximalizují výraz.

$$\sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (x_i \cdot x_j), \quad (3.17)$$

Přičemž platí omezení

$$\begin{aligned} \alpha_i &\geq 0 \\ \sum_i \alpha_i y_i &= 0 \end{aligned} \quad (3.18)$$

Výraz má dvě významné vlastnosti, má jediné globální minimum, které lze efektivně najít, a datové body do výrazu vstupují ve formě skalárního součinu jednotlivých dvojic. Druhá vlastnost platí i pro rovnici lineárního oddělovače.

Díky omezení při hledání α_i platí, že lineární oddělovač má nulové váhy α_i pro každý datový bod kromě těch bodů, které jsou nejbližší vlastnímu oddělovači. Tyto nejbližší body se nazývají podpůrné vektory (support vectors). Jejich funkcí je podpora oddělovací hadroviny, která na nich spočívá. Ostatní body nejsou pro oddělovače nutné, takže metoda SVM je schopna najít trénovací příklady, které jsou pro nalezení oddělovače tříd podstatné. Nelze však očekávat, že lineární oddělovač bude nalezen přímo v originálním výstupním prostoru x . Lineární oddělovače lze hledat ve vícerozměrném prostoru $F(x)$ tak, že se nahradí člen $x_i \cdot x_j$ členem $F(x_i) \cdot F(x_j)$. Náhrada má stejný efekt pro každý učící algoritmus, ale v tomto případě jsou ke skalárnímu součinu zvláštní vlastnosti. Platí, že $F(x_i) \cdot F(x_j)$ není nutné stanovit podle výpočtu F pro všechny body.

$$F(x_i) \cdot F(x_j) = (x_i \cdot x_j)^2, \quad (3.19)$$

kde $(x_i \cdot x_j)^2$ se nazývá jádrová funkce. V SVM je to funkce, která může být aplikována na dvojice vstupních dat k vyhodnocení skalárního součinu v nějakém odpovídajícím prostoru. Díky tomu jde tedy najít lineární oddělovače ve vícerozměrném prostoru $F(x)$ jednoduše náhradou jádrové funkce za $K(x_i, x_j)$. Tedy jde provádět učení ve vícerozměrném prostoru, ale stačí počítat pouze jádrové funkce místo úplného seznamu atributů pro každý datový bod.

Nalezené lineární oddělovače lze mapovat zpět do původního prostoru. Díky tomu získáme libovolně zvlněné, nelineární hranice mezi pozitivními a negativními příklady [32], [33].

Tato metoda byla použita v této diplomové práci. Metoda byla vybrána kvůli své jednoduchosti a efektivitě. Na rozdíl od neuronových sítí není nutné nastavovat parametry (počet neuronů, typ aktivační funkce a učícího algoritmu, apod.). Na rozdíl od diskriminační metody a k-NN má lepší generalizační schopnosti a je více efektivní při řešení nelineárních úloh. Jelikož pro práci je k dispozici hypnogram, mohou být využity výhody učení s učitelem na rozdíl od shlukových metod. Například u k-means, kde metoda rozdělí data podle vnitřních vlastností, následně ale musí být provedeno postzpracování nebo analýza vzniklých skupin. Tato metoda není jednoduchá a vyžaduje expertní znalosti. Rozhodovací stromy se více hodí pro binární klasifikaci nebo klasifikaci do menšího počtu skupin, jinak se stávají nepřehledné a je potřeba hlídat nastavení různých parametrů pro dosažení optimálního řešení.

3.3.7 Hodnocení úspěšnosti klasifikace

3.3.7.1 K-fold kříživá validace

K odhadu úspěšnosti klasifikačního modelu slouží tzv. křížová validace [34]. Originální set dat je náhodně rozdělen do k subsetů. Z těchto subsetů je vybrán jeden (validation set), tedy set pro testování. Zbytek ($k-1$) subsetů je použit pro trénink. Tento proces se poté několikrát opakuje. Každý ze subsetů je použit právě jednou pro testování. Všechna data jsou v této metodě použita jak pro trénování, tak pro testování. Počet foldů se používá buď $k=5$, nebo $k=10$ [35], [36].

3.3.7.2 Senzitivita, specificita, úspěšnost detekce

Senzitivita, specificita a úspěšnost detekce se používá k hodnocení spolehlivosti klasifikace.

Senzitivita

Parametr udává, s jakou pravděpodobností dojde k pozitivní detekci u skutečně pozitivních případů. Čím vyšší hodnota, tím je méně falešně negativních. Vypočítat se dá pomocí

$$Se = \frac{TP}{TP + FN}, \quad (3.20)$$

kde TP (z angl. true positive) je počet správně detekovaných parametrů a FN (z angl. false negative) jsou falešně negativní detekce. Senzitivita je v rozsahu 0-1, tato hodnota se poté násobí stem, abychom dostali hodnotu pravděpodobnosti v procentech.

Specificita

Parametr udává, s jakou pravděpodobností test vybral případy, u nichž zkoumaný znak nenastal. Čím vyšší hodnota, tím je méně falešně pozitivních. Vypočítá se pomocí

$$Sp = \frac{TN}{TN + FP}, \quad (3.21)$$


kde TN (z angl. true negative) je počet skutečně negativních, FP (z angl. false positive) jsou falešné pozitivní detekce. Specificita je v rozsahu 0-1, tato hodnota se poté násobí stem, abychom dostali hodnotu pravděpodobnosti v procentech.

4. ANALÝZA PSG SIGNÁLU ZE STUDIE RELIEF

V práci jsou použita data ze studie RELIEF, která se zabývala léčbou pacientů s farmakorezistentní hypertenzí pomocí metody ablace renálního sympatiku. Studii poskytla spánková laboratoř Fakultní nemocnice u sv. Anny v Brně. Studie se týkala 53 pacientů, z nichž pro semestrální práci bylo využito prvních 10 záznamů. Polysomnografické vyšetření bylo u pacientů provedeno noc před zákrokem a poté šest měsíců po zákroku.

4.1 Popis dat

Z celkového PSG záznamu byly vybrány signály EEG, EOG a EMG, resp. EEG kanál CzOz, EOG pro levé oko a EMG pro pohyb brady. Umístění elektrod vidíme na Obr 4, Obr 5 a Obr 6. Vzorkovací frekvence byla 256 Hz. U EEG byl použit systém rozmístění elektrod „10 – 20“. Aby mohla být data zpracována v programu MATLAB (verze MATLABR2015a), musela být data převedena z původního formátu (EDF) na formát ASCII. Tento převod byl proveden pomocí konvertoru EDF-to-ASCII.



Obr 4 Rozmístění elektrod pro EEG ve studiu RELIEF

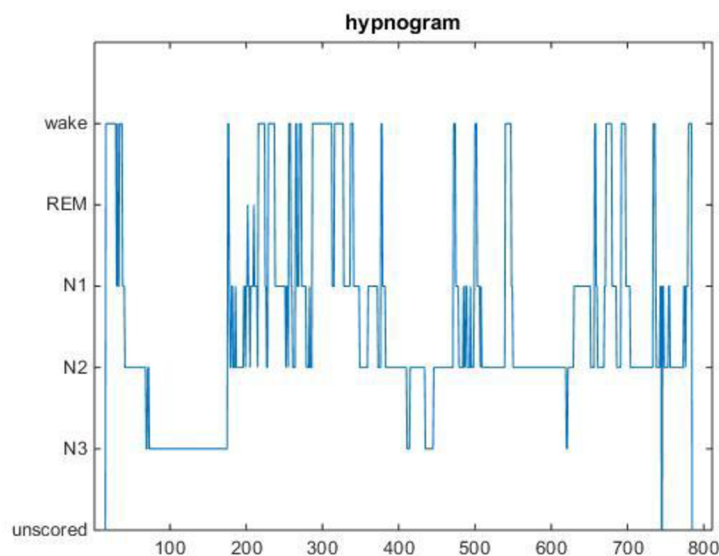


Obr 5 Rozmístění elektrod pro EOG ve studiu RELIEF



Obr 6 Rozmístění elektrod pro EMG ve studiu RELIEF

V programovém prostředí MATLAB jsou signály načteny a uloženy do souboru *.mat. Signály použité v práci jsou následně rozděleny pomocí hypnogramu, 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, příklad vidíme na Obr 7, byly vybrané signály rozděleny do jednotlivých spánkových fází.



Obr 7 Ukázka hypnogramu

4.2 Použité metody statistické analýzy

Pro odlišení spánkových fází je nutné nalézt více parametrů, pomocí kterých jsme schopni správně jednotlivé fáze klasifikovat.


Analýza rozptylu (ANOVA) je základní statistickou metodou, která zjišťuje, zda jsou mezi dvěma nebo více skupinami významné rozdíly. Metoda srovnává rozptyly hodnot. Cílem je, aby rozptyl uvnitř klasifikačních tříd byl co nejmenší a zároveň, aby mezi jednotlivými třídami byl co největší. Analýza rozptylu je platná platí-li 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 funkce Matlabu *lillietest*. Předpoklady analýzy rozptylu nebyly splněny, proto byl použit Kruskal-Wallisův test.

Kruskal-Wallisův test nevyžaduje předpoklad normality pozorovaných hodnot. Neparametrické testy mají menší sílu, což je nutné kompenzovat větší velikostí vzorku. Kruskal-Wallisův test je založen na pořadí pozorovaných hodnot, kdy nejdříve hodnoty uspořádáme podle velikosti (všechny do jednoho) a následně se jim přiřadí pořadí. Nulová hypotéza H_0 tohoto testu předpokládá u skupin shodnost mediánu, naopak u alternativní hypotézy H_1 předpokládáme, že alespoň jedna dvojice mediánů se nerovná. Platnost nulové hypotézy určujeme podle p-hodnoty, která je definována jako nejmenší hladina významnosti testu α (obvykle $\alpha = 0,05$), při které zamítáme nulovou hypotézu. Pokud nám při hodnocení statistického testu vyjde p-hodnota menší než α , nulovou hypotézu zamítneme a jedná se o statisticky významný výsledek na dané hladině významnosti α . Pokud je p-hodnota větší než α , nulovou hypotézu nezamítáme, platí H_0 . Pro výpočet Kruskal-Wallisova testu byla v Matlabu použita funkce *kruskalwallis*.

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. Použit byl 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.

Další metodou, při které si můžeme graficky znázornit výsledky, jsou krabicové grafy (boxploty). Krabicové grafy se 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. Pro vykreslení grafů byla využita funkce Matlabu *boxplot*. Na Obr 8 vidíme příklad boxplotu. [30], [31]



Obr 8 Příklad boxplotu


4.3 Analýza PSG dat v časové oblasti

Pro analýzu v časové oblasti bylo vybráno 10 pacientů, u kterých byl vybrán signál EEG, EOG a EMG. Analýza v časové oblasti se provádí pomocí různých parametrů. Pro tuto práci byly vybrány tyto parametry: aktivita, koeficient šikmosti, koeficient špičatost, entropie, 75. percentil, směrodatná odchylka, střední hodnota, mobilita a složitost. Každý parametr byl vypočítán pro všechny fáze EEG, EOG, EMG. Signály byly tedy rozděleny na jednotlivé 30s epochy a vše bylo vypočítáno pro prvních 10 záznamů. Do Tab 2 byl následně zapsán počet epoch v daných spánkových fázích.

Tab 2 Celkový počet 30s epoch jednotlivých fází

Záznam	REM	N1	N2	N3	WAKE
1	2	157	358	122	129
2	18	30	624	79	30
3	0	246	532	0	127
4	21	49	335	174	207
5	121	50	431	86	134
6	48	55	229	248	171
7	68	166	320	206	117
8	32	164	138	65	213
9	51	84	190	182	284
10	115	168	278	103	212
Celkem	476	1169	3435	1265	1624

Následně byly vypočítány parametry z jednotlivých fází. Na Obr 9 bvidíme aktivitu signálů, která patří mezi Hjorthovy deskriptory. Aktivita nám ukazuje rozptyl (střední kvadratickou odchylku) úrovně signálu v epoše. Je plochou pod výkonovým spektrem a vyjadřuje střední výkon. Hodnota odpovídá hodnotě nultého momentu výkonového spektra. Ostatní boxploty parametrů jsou zobrazeny v PŘÍLOHA A.



Obr 9 Aktivita EEG, EOG, EMG

Poté byl proveden statistický test. Z Kruskal-Wallisova testu vyplývá, že p pro aktivitu u EEG, EOG i EMG je menší než 0,05, což znamená, že hodnoty jsou statisticky významné.

Pokud se podíváme na Tab 3, vidíme výsledky statistické analýzy například pro aktivitu EMG, kde vidíme první dva sloupečky, ve kterých jsou porovnávány fáze. Z Tab 3 lze zhodnotit, že pokud čísla mezi 3. a 5. sloupečkem prochází nulou, pak je porovnání statisticky nevýznamné. Pokud bychom vypsali pouze nevýznamné dvojice, pak to je v tomto případě pouze dvojice N1-WAKE. V Tab 4 jsou vypsány fáze, mezi kterými byl odhalen statisticky významný rozdíl v hodnotách sledovaného parametru podle Kruskal-Wallisova testu a následného multcompare testu.

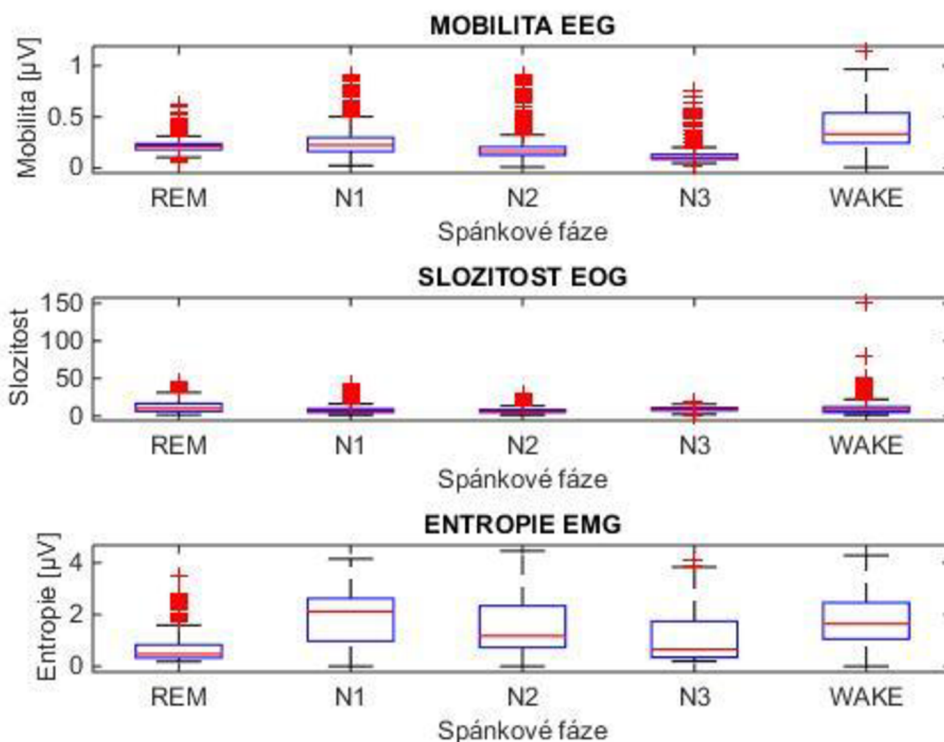
Tab 3 Příklad statistického testu

Spánkové fáze					Statisticky významný rozdíl
REM	N1	-1.1934	-1.0719	-0.9504	ano
REM	N2	-1.4295	-1.3080	-1.1865	ano
REM	N3	-0.7888	-0.6673	-0.5458	ano
REM	WAKE	-1.1742	-1.0527	-0.9312	ano
N1	N2	-0.3577	-0.2362	-0.1147	ano
N1	N3	0.2831	0.4046	0.5261	ano
N1	WAKE	-0.1023	0.0192	0.1407	ne
N2	N3	0.5192	0.6407	0.7623	ano
N2	WAKE	0.1339	0.2554	0.3769	ano
N3	WAKE	-0.5069	-0.3854	-0.2639	ano

Tab 4 Vybrané parametry vypočítané z epoch jednotlivých spánkových fází vhodných pro automatickou klasifikaci podle analýzy v časové oblasti

Parametr	Signál	Fáze statisticky významné od zbývajících fází	Statisticky nevýznamné dvojice fází
AKTIVITA	EEG	N3	REM-WAKE, N1-N2
	EOG	WAKE	REM-N1, REM-N2, REM-N3, N1-N2, N1-N3
	EMG	N2, N3, REM	N1-WAKE
ŠIKMOST	EEG	N3, WAKE	REM-N1, REM-N2
	EOG	N2	REM-WAKE, N1-N3
	EMG	WAKE	REM-N3, N1-N2
ŠPIČATOST	EEG	N3	REM-N1, REM-N2, REM-WAKE, N1-N2, N1-WAKE, N2-WAKE
	EOG	N2, N3	REM-N1, REM-WAKE
	EMG	N3, REM, WAKE	N1-N2
ENTROPIE	EEG	N3	REM-N2, N1-WAKE
	EOG	N2	REM-N1, N3-WAKE
	EMG	N1, N2, N3, REM, WAKE	-
MOBILITA	EEG	N1, N2, N3, REM, WAKE	-
	EOG	N2, N3, REM	N1-WAKE
	EMG	N2	REM-N3, N1-WAKE
PERCENTIL	EEG	N3	REM-N2, N1-WAKE
	EOG	N2, REM, WAKE	N1-N3
	EMG	N2, N3, REM	N1-WAKE
SMĚRODATNÁ ODCHYLKA	EEG	N2, REM	N1-N3, N1-WAKE, N3-WAKE
	EOG	N2, WAKE	REM-N1, REM-N3, N1-N3
	EMG	N2, N3, REM	N1-WAKE
STŘEDNÍ HODNOTA	EEG	N3	N1-N2, N1-WAKE, N2-WAKE
	EOG	-	REM-N3, N1-N2, N1-WAKE, N2-WAKE
	EMG	N2, REM	N1-N3, N1-WAKE, N3-WAKE
SLOŽITOST	EEG	N3	REM-WAKE, N1-N2
	EOG	N1, N2, N3, REM, WAKE	-
	EMG	N2	REM-N3, N1-WAKE

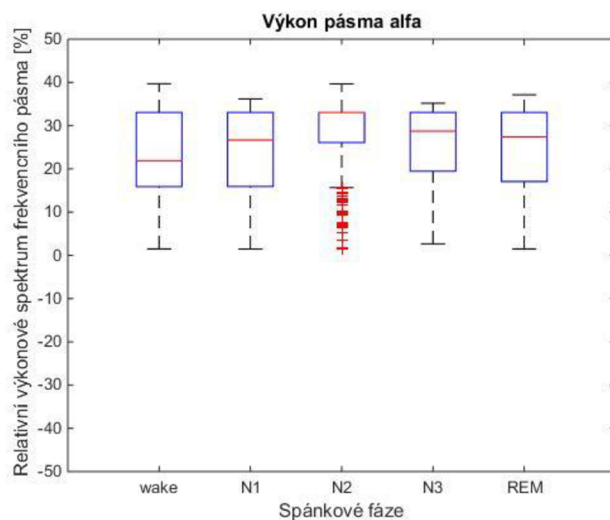
Pokud bychom porovnali parametry fází statisticky významných od zbývajících fází z testu s boxploty, vidíme na Obr 10, že boxploty nejsou zcela jednoznačné. Příkladem je uvedený boxplot entropie EMG, mobility EEG a složitost u EOG. V krabicových grafech vidíme, že mediány jsou téměř totožné, minima také. Liší se pouze maximem. Z boxplotů tedy nemůžeme zcela jednoznačně říci, že jsou fáze od sebe odlišitelné.



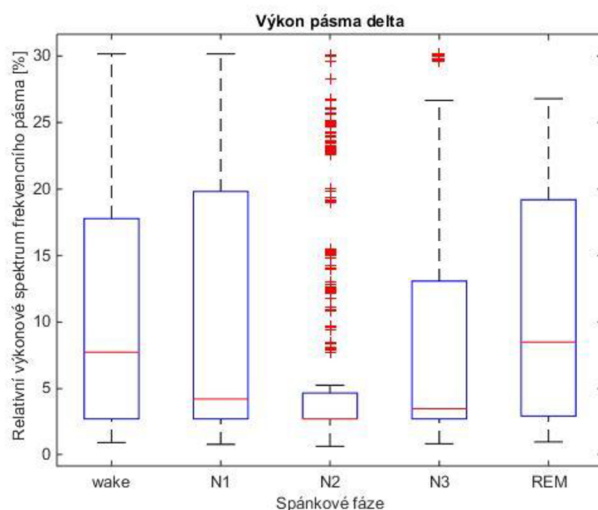
Obr 10 Parametry vykazující statistický významný rozdíl mezi spánkovými fázemi

4.4 Analýza ve frekvenční oblasti

Pro výpočet frekvenčních parametrů bylo vytvořeno spektrum jednotlivých signálů. Spektrum bylo vypočítáno pomocí $abs(fft())$. U signálu EEG byl poté ještě celkový rozsah spektra rozdělen na pásma theta, delta, alfa a beta. Pro jednotlivá pásma bylo vypočítáno relativní výkonové spektrum u dané fáze. Výkony byly následně vykresleny pomocí krabicových grafů. Na Obr 11 vidíme relativní výkonové spektrum pásma alfa. Pokud bychom se podívaly na hodnoty krabicových grafů, můžeme usoudit, že jednotlivé fáze se od sebe téměř neliší, pouze N2 by se mohlo teoreticky pomocí parametru alfa odlišit. Na Obr 12 vidíme relativní výkonové spektrum pásma delta u spánkových fází. Pomocí parametru delta by bylo možné rozeznat například fázi N2, která je od ostatních odlišná, ovšem jednotlivé krabicové grafy se překrývají, proto to není zcela přesné tvrzení. Proto byla následně provedena statistická analýza pomocí Kruskal-wallisova testu a následného multcompare testu.



Obr 11 Výkon pásma alfa v jednotlivých spánkových fázích



Obr 12 Výkon pásma delta v jednotlivých spánkových fázích

V Tab 5 vidíme, že podle statistické analýzy výkon pásma alfa není statisticky významný, což bylo odhadnuto i pomocí krabicových grafů. Výkony delta, theta a beta jsou významné pro odlišení fáze N2 a REM.

Tab 5 Tabulka parametrů relativního výkonového spektra jednotlivých pásem v EEG spánkových fázích vhodných a nevhodných pro automatickou klasifikaci

Parametr	Fáze statisticky významné od zbývajících fází	Statisticky nevýznamné dvojice fází
Výkon alfa	-	REM-N2,N1-N3,N1-WAKE, N3-WAKE
Výkon beta	N2,REM	N1-N3,N1-WAKE,N3-WAKE
Výkon delta	N2,REM	N1-N3,N1-WAKE, N3-WAKE
Výkon theta	N2,REM	N1-N3,N1-WAKE,N3-WAKE

Následně bylo vypočítáno výkonové spektrum pro signály EOG a EMG pro jednotlivé pacienty zvlášť. Tento postup byl zvolen kvůli častějším artefaktům u těchto signálů.

Pacienti se od sebe mohou diametrálně lišit. Proto byl testován nejprve každý pacient zvlášť. Tentokrát byl proveden pouze statistický test, stejný jako v předchozích případech. Výsledky byly zaznamenány do Tab 6.

Tab 6 Tabulka spánkových fází vhodných a nevhodných pro automatickou klasifikaci u výkonových spekter EOG a EMG pro každého pacienta zvlášť

Pacient-spektrum	Signál	Fáze statisticky významné od zbývajících fází	Statisticky nevýznamné dvojice fází
1	EOG	-	REM-N1,REM-N2,REM-N3,N1-N2,N3-WAKE
	EMG	-	REM-N1,REM-N2,N1-N2,N3-WAKE
2	EOG	WAKE	REM-N1,REM-N3,N1-N3,N2-N3
	EMG	-	REM-N1,REM-N2,REM-N3,N1-N2,N3-WAKE
3	EOG	WAKE	N1-N2
	EMG	WAKE	N1-N2
4	EOG	-	REM-WAKE,N1-N2,N2-N3
	EMG	REM,WAKE	N1-N2,N1-N3,N2-N3
5	EOG	N3, WAKE	REM-N2,N1-N2,
	EMG	-	REM-N1,REM-N3,N1-N3,N2-WAKE
6	EOG	-	REM-N1,REM-N2,N3-WAKE
	EMG	N2, WAKE	REM-N3,N1-N3,
7	EOG	-	
	EMG	N2,N3,WAKE	REM-N1
8	EOG	N3,WAKE	REM-N1,REM-N2
	EMG	-	REM-N3,N1-N2,N1-WAKE
9	EOG	WAKE	REM-N1,REM-N2,REM-N3,N1-N2,N2-N3
	EMG	REM,WAKE	N1-N2,N1-N3,N2-N3
10	EOG	REM,N2,WAKE	N1-N3
	EMG	N3	REM-N1,N2-WAKE

Z výsledků vidíme, že ve většině případů pro odlišení fáze WAKE je výkonové spektrum vhodným parametrem. Žádné větší výkyvy ve výsledcích nebyly nalezeny. Následně byl tedy stejný test proveden pro soubor všech pacientů dohromady. Výsledky jsou zaznamenány v Tab 7.

Tab 7 Tabulka spánkových fází vhodných a nevhodných pro automatickou klasifikaci podle výkonového spektra signálů EOG a EMG

Spektra	Fáze statisticky významné od zbývajících fází	Statisticky nevýznamné dvojice fází
EOG	REM,N1,N3	N2-WAKE
EMG	REM,N1,N3	N2-WAKE

Podle testu vyšly statisticky významné fáze REM, N1 a N3, což se neshoduje s předchozím testem. Proto byla tato analýza zamítnuta pro další použití.

Ze spektra bylo poté zjištěno maximum, minimum a průměr. Parametry byly opět statisticky vyhodnoceny. Výsledky vidíme v Tab 8. Parametry byly ve většině případů statisticky významné, proto byly vybrány pro následnou automatickou klasifikaci.

Tab 8 Tabulka spánkových fází vhodných a nevhodných pro automatickou klasifikaci u maxim, minim a průměrů z výkonových spekter EEG, EOG a EMG

Parametr	Fáze statisticky významné od zbývajících fází	Statisticky nevýznamné dvojice fází
MIN spektra EEG	WAKE, N1, N2, N3, REM	-
MIN spektra EOG	WAKE, N1, N2, N3, REM	-
MIN spektra EMG	WAKE, N1, N2, N3, REM	-
MAX spektra EEG	WAKE, N1, N2, N3, REM	-
MAX spektra EOG	N1,N2,WAKE	REM-N3
MAX spektra EMG	WAKE, N1, N2, N3, REM	-
PRŮMĚR spektra EEG	WAKE, N1, N2, N3, REM	-
PRŮMĚR spektra EOG	WAKE, N1, N2, N3, REM	-
PRŮMĚR spektra EMG	WAKE, N1, N2, N3, REM	-

4.5 Vybrané parametry

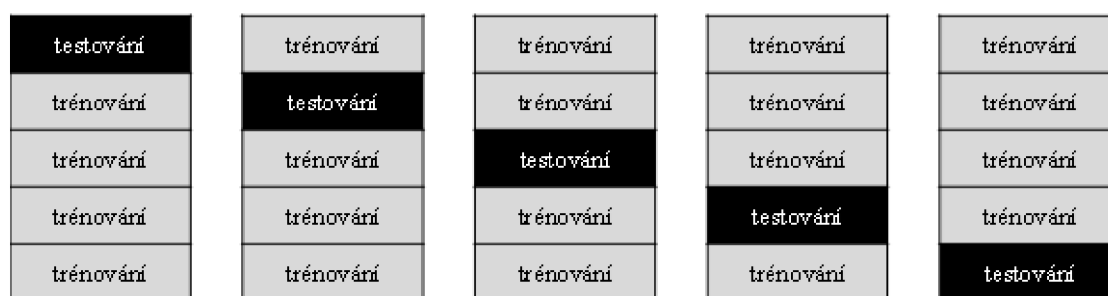
Podle analýzy v časové a frekvenční oblasti s následným statistickým vyhodnocením bylo vybráno 23 parametrů, které byly zaznamenány do Tab 9.

Tab 9 Parametry vybrané pro následnou klasifikaci

Signály	Parametry
EEG	Aktivita, špičatost, entropie, mobilita, 75. Percentil, střední hodnota, složitost, minimum spektra, maximum spektra, průměr spektra
EOG	Aktivita, šikmost, entropie, složitost, minimum spektra, průměr spektra
EMG	Šikmost, entropie, mobilita, složitost, minimum spektra, maximum spektra, průměr spektra

5. KLASIFIKACE PSG SIGNÁLŮ

Pomocí statistické analýzy byly vybrány parametry vhodné pro automatickou klasifikaci. Klasifikace je provedena pomocí metody SVM (metoda podpůrných vektorů). Metoda využívá matici vybraných parametrů. Výhodné je mít v matici velký počet epoch, pro lepší výsledky klasifikace. Dále je nutné mít vektor odpovídajících výstupních hodnot (target vector), kde je každé epoše přiřazen číselný kód podle spánkových fází, ze které daná epocha pochází. Vektor tedy obsahuje hodnoty z hypnogramu. Příklad – v matici parametrů je epocha REM, poté ve vektoru odpovídajících výstupních hodnot bude na stejné pozici číslo 5. Takto připravená data poté projdou programem *klasifikace.mat*. Program funguje na principu trénování a testování. Pomocí *ifold* je vybrána hodnota 5 nebo 10. Tedy všechny epochy se rozdělí náhodně na 10 nebo 5 souborů- Poté pokud bychom měli *ifold=10*, tak se epochy z 9 souborů použijí na trénování a epochy ze zbývajících 1 souboru na testování.




Obr 13 Příklad křížové validace pro *nfold=5*

Program klasifikuje epochy pomocí SVM s lineární nebo radiální bází, které jsou popsány v 3.3.6. Po klasifikaci je vyhodnocena úspěšnost detekce pomocí senzitivity, specifity a správnosti detekce, která je vypočítána jako počet správně detekovaných epoch ku počtu epoch (v %).

5.1 Klasifikace pomocí vybraných parametrů

Pro první klasifikaci byla použita matice vybraných parametrů, *nfold=5*. Při použití *nfold=10* byly výsledky téměř totožné.




Obr 14 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

Na Obr 14 se nachází 6 grafů. První graf ukazuje procentuální úspěšnost detekce trénovacích dat. Po pravé straně vidíme senzitivitu a specifitu detekce v procentech. V druhém řádku jako první vidíme procentuální úspěšnost detekce testovacích dat. Po pravé straně potom vidíme senzitivitu a specifitu detekce v procentech.

V tomto případě vidíme, že úspěšnost detekce u trénovacích dat je více než 70%. Senzitivita poté vyšla přes 60% u REM, N2 a N3. Naopak nízká je u N1 a WAKE. Specifita vyšla nízká u N2 a u WAKE. U testovacích dat vyšla úspěšnost detekce vyšší než u trénovacích. Výsledky senzitivity a specifity jsou podobné jako u trénovacích dat. Můžeme tedy říct, že trénovací data dobře reprezentují data testovací. Fáze REM, N2 a N3 jsou relativně správně rozpoznány.

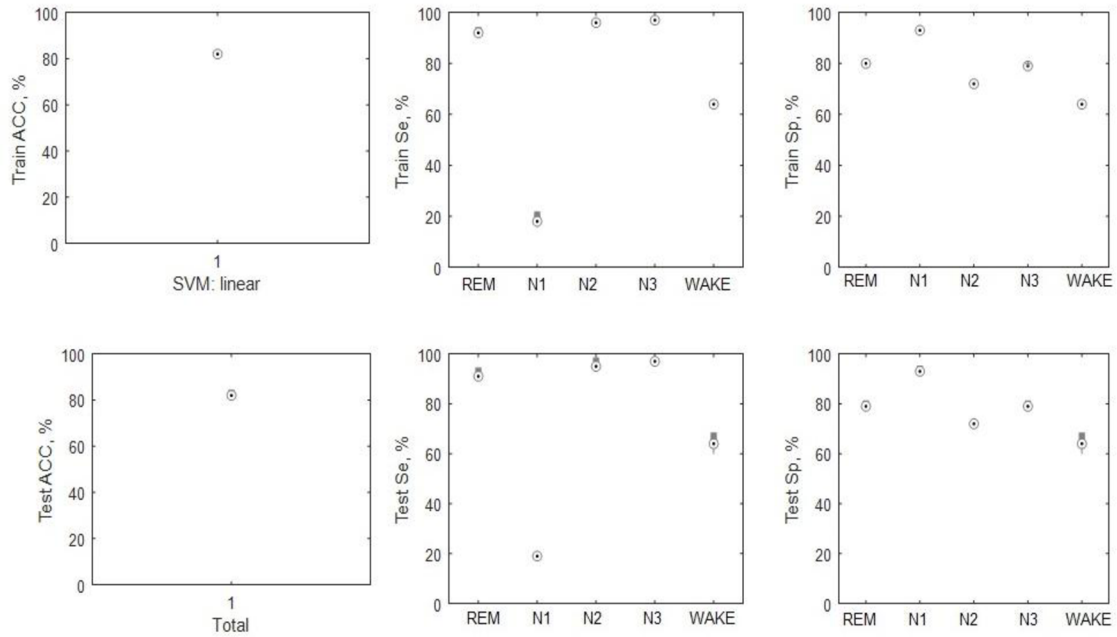
V případě radiální bazové funkce (viz Obr. 16) vyšla hodnota úspěšnosti detekce vyšší než u lineární verze. Celkově vidíme, že klasifikace pomocí radiální bazové fáze vyšla lépe - fáze REM téměř o 10%, N1 téměř o 20%, N2 bylo podobné, N3 o 5% a WAKE o 10%.



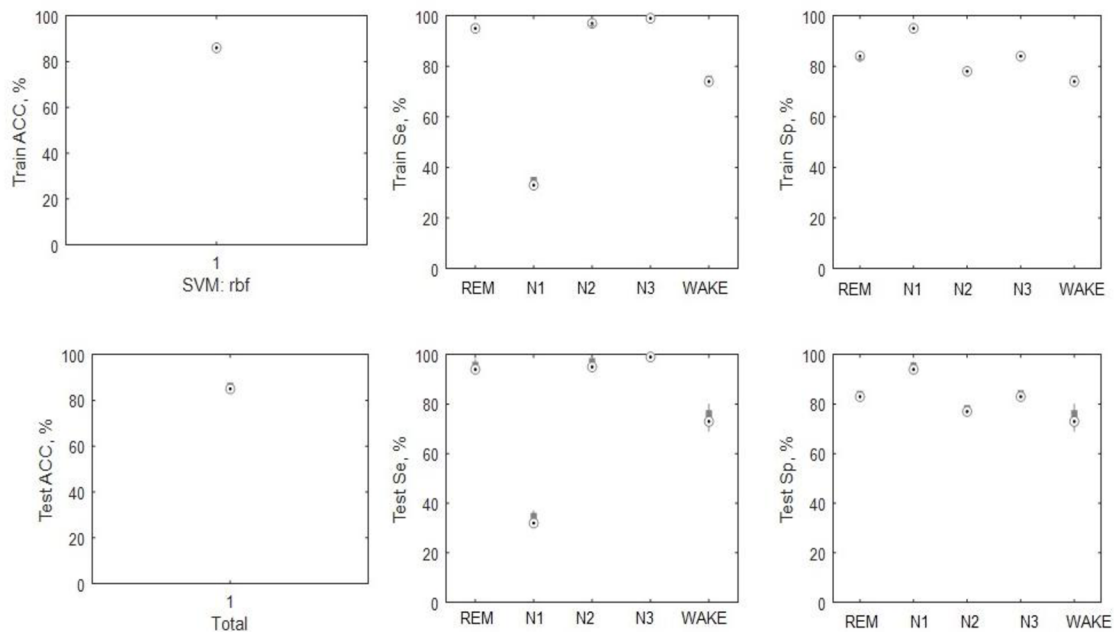
Obr 15 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

5.2 Klasifikace pomocí EEG parametrů

Pokud použijeme pouze všechny parametry vypočítané z EEG, dostaneme matici s 7969 epochami, u kterých je vypočítáno 16 parametrů. Epochy opět podrobíme klasifikaci a poté určujeme správnost klasifikace. Na Obr 16 vidíme správnost klasifikace pomocí parametrů z EEG signálu. Klasifikace opět ukázala, že špatně klasifikovatelná je fáze N1. Fáze WAKE je oproti metodě v kapitole 5 lépe klasifikována. Celkově výsledky pro klasifikaci pouze pomocí parametrů EEG vyšly lépe než u vybraných parametrů pro EEG, EOG a EMG.



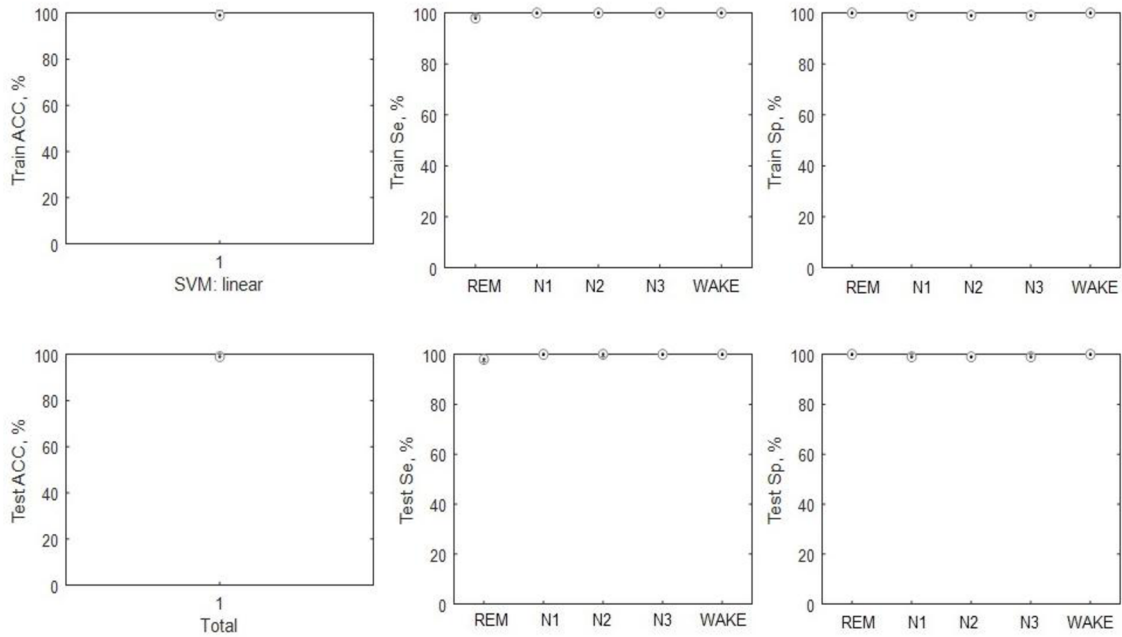
Obr 16 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat



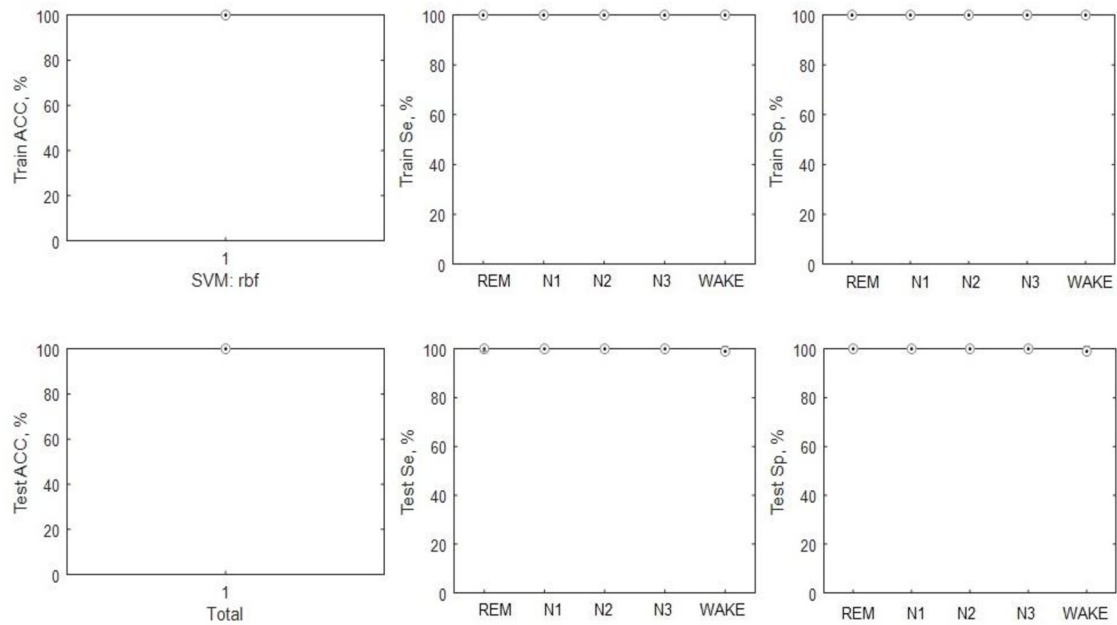
Obr 17 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

5.3 Klasifikace pomocí všech parametrů ze signálů EEG, EOG a EMG

Pokud bychom použili všechny vypočítané parametry u všech epoch všech signálů, dostaneme matici s 40ti parametry a 7969 epochami. Na Obr 18 a Obr 19 vidíme, že úspěšnost klasifikace je v obou případech téměř 100%. V tomto případě nejspíše došlo k přeučení SVM, proto vyšly téměř 100% výsledky.

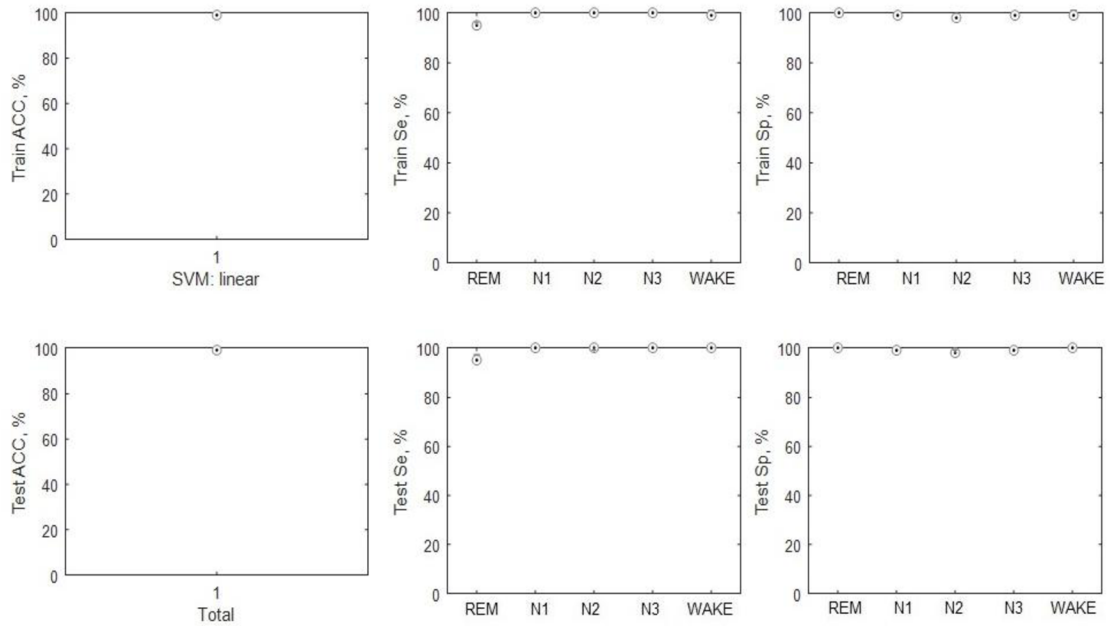


Obr 18 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

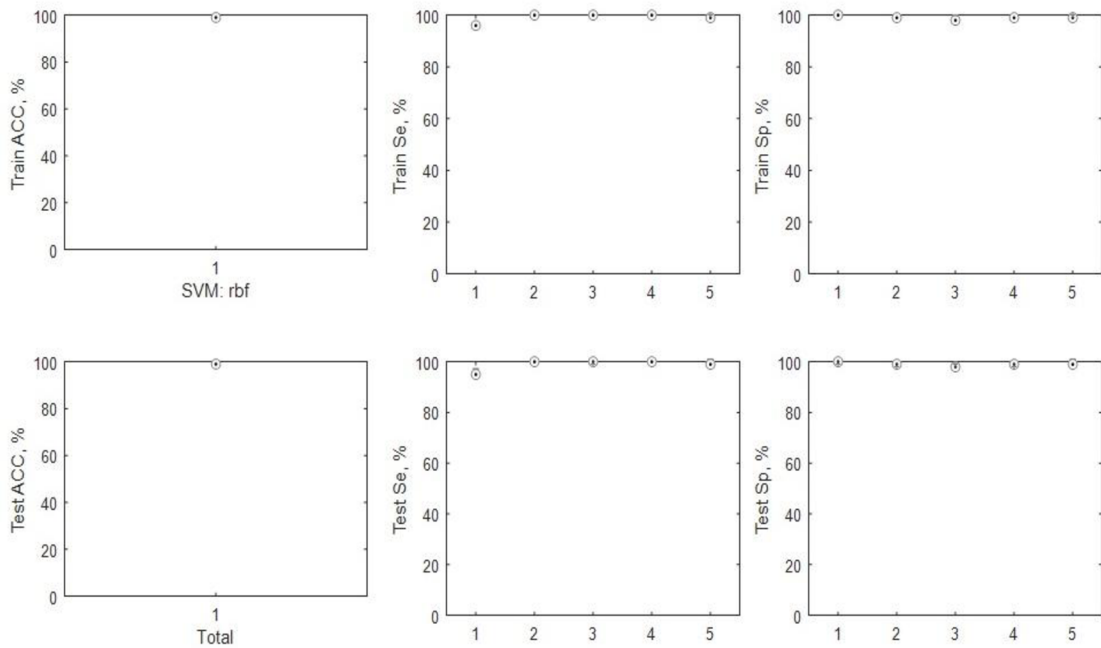


Obr 19 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

Pokud bychom použili vypočítané parametry u všech epoch signálů EOG a EMG, dostaneme matici s 24mi parametry a 7969 epochami. V obou případech, na Obr 20 a Obr 21, vidíme, že nejhůře klasifikovaná je fáze REM, která se pohybuje kolem 95%. Ostatní fáze jsou téměř na 100%.



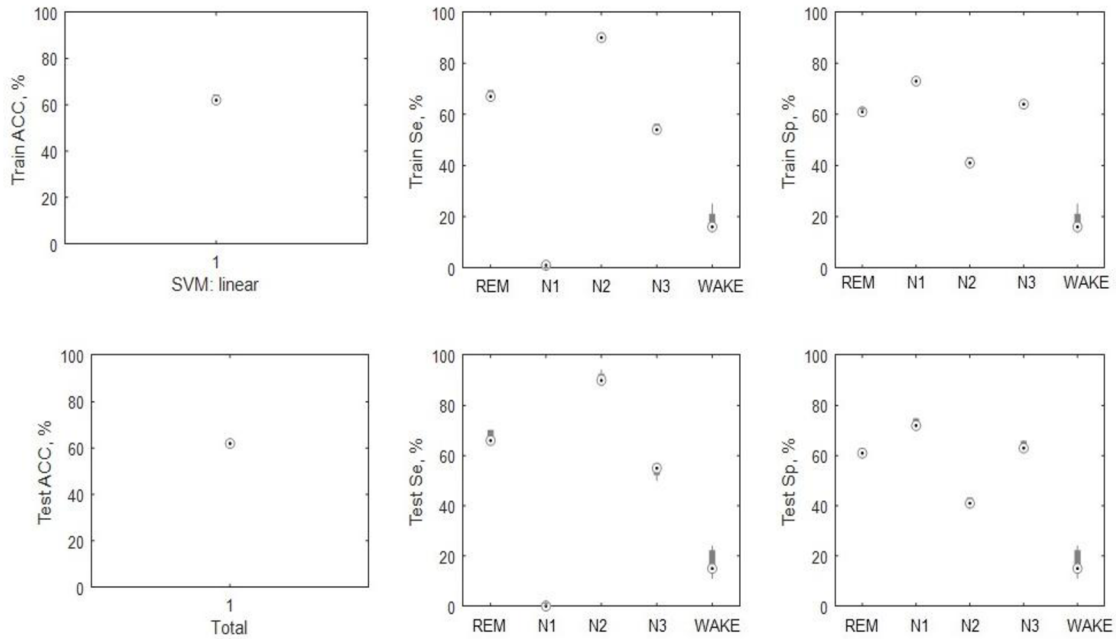
Obr 20 Vyhodnocení klasifikace SVM-lineární pomocí specificity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat




Obr 21 Vyhodnocení klasifikace SVM-radiální pomocí specificity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

5.4 Klasifikace pomocí časových parametrů

Matice vytvořená pouze z parametrů vypočítaných v časové oblasti má velikost 27 s 7969 epochami. Podle časových parametrů je nejhůře klasifikovaná fáze WAKE a N1, což je patrné z Obr 22 a Obr 23.



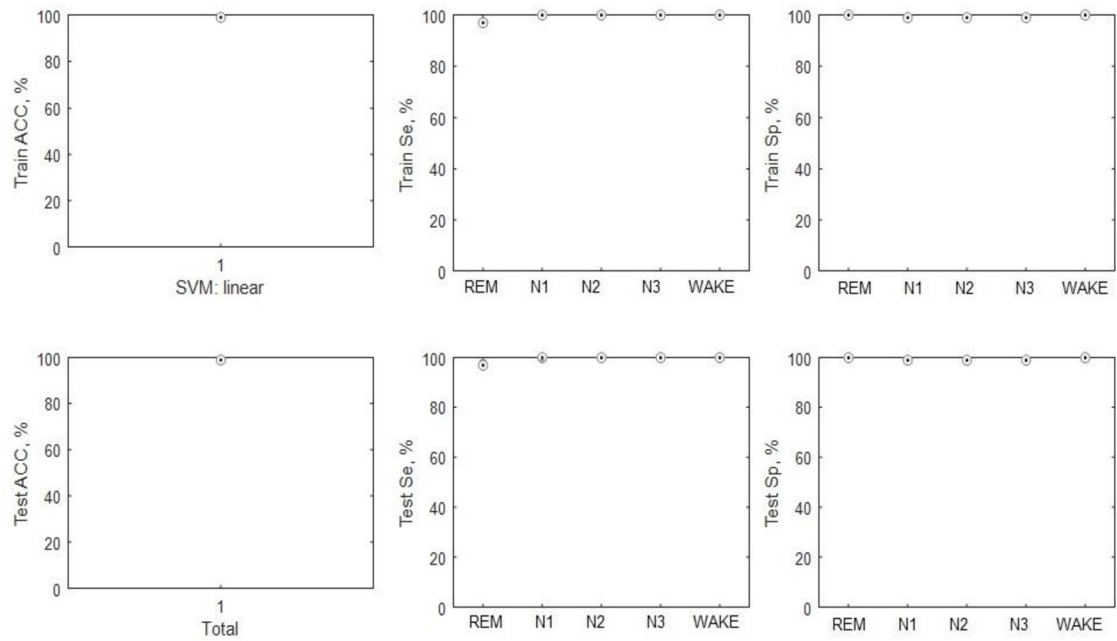
Obr 22 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat



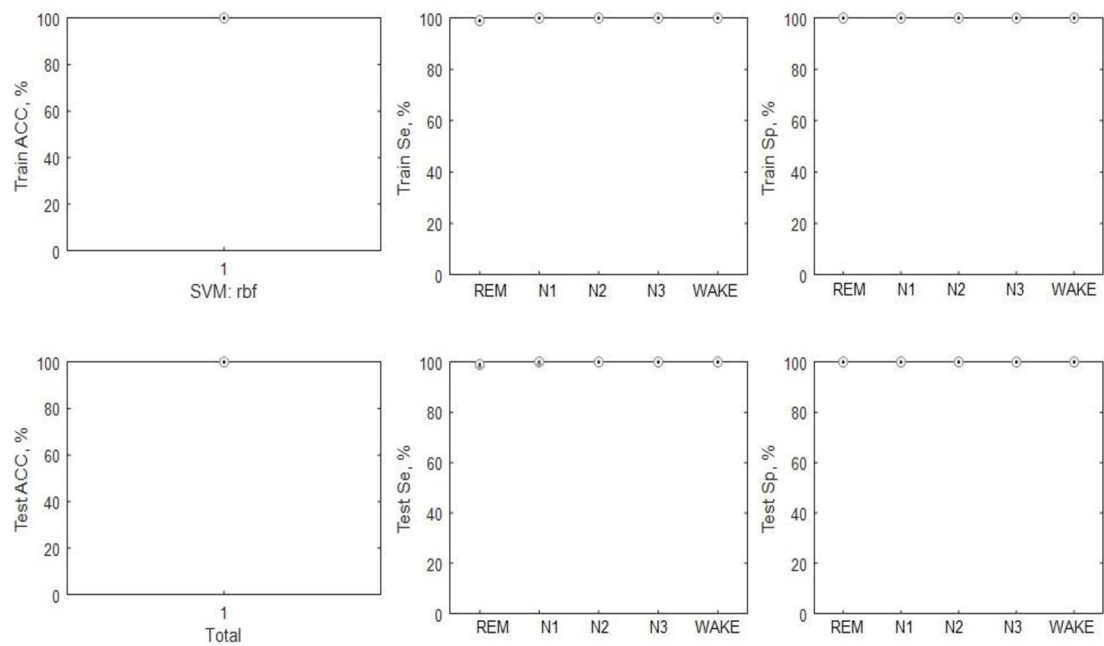
Obr 23 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

5.5 Klasifikace pomocí frekvenčních parametrů

Poslední klasifikace byla provedena jen pomocí frekvenčních parametrů (13). Podle hodnocení úspěšnosti klasifikace vyšla v obou případech klasifikace téměř 100%, což je viditelné na Obr 24 a Obr 25. V tomto případě nejspíše došlo k přeučení SVM, proto vyšly téměř 100% výsledky.



Obr 24 Vyhodnocení klasifikace SVM-lineární pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat



Obr 25 Vyhodnocení klasifikace SVM-radiální pomocí specifity (Sp), senzitivity (Se) a úspěšnosti (ACC) detekce na trénovací (nahore) a testovací (dole) množině dat

5.6 Zhodnocení úspěšnosti klasifikace

Klasifikace pomocí SVM a křížové validace byla provedena a výsledky byly zapsány v předchozích částech kapitoly 5. Z výsledků zobrazených v této části je patrné, že klasifikace vybranou metodou je úspěšná. Nejlépe vyšla klasifikace pomocí parametrů ve frekvenční oblasti, hůře poté klasifikace pomocí parametrů v časové oblasti. Často se od sebe špatně rozeznávají například fáze N1 a N2, jelikož si jsou podobné, problém bývá i s detekcí REM fáze, jelikož je podobná fázím N1 a WAKE. Pomocí klasifikace navrženou metodou však nejhůře vycházela klasifikace fáze N1, jelikož tato fáze je považována za přechodovou fází a její hodnoty jsou podobné ostatním fázím. Nejlepší výsledek se poté očekává od fází WAKE a N3.

Pokud bychom hodnotili úspěšnost klasifikace pomocí parametrů vybraných statistickým testem, nevyšla by nejlépe, výsledky jsou zapsány v Tab 10 a Tab 11.

Tab 10 Se(senzitivita) a Sp(specificita) trénovacích a testovacích dat u vybraných parametrů pomocí časové a frekvenční analýzy, lineární SVM

%(přibližně)	REM	N1	N2	N3	WAKE
Se train	75	10	90	65	35
Se test	75	10	90	70	35
Sp train	70	80	50	70	35
Sp test	70	80	50	70	35

Tab 11 Se(senzitivita) a Sp(specificita) trénovacích a testovacích dat u vybraných parametrů pomocí časové a frekvenční analýzy, radiální SVM

%(přibližně)	REM	N1	N2	N3	WAKE
Se train	80	30	95	70	50
Se test	80	30	95	70	50
Sp train	75	80	60	75	50
Sp test	75	85	60	75	45

Z tabulek je patrné, že lépe vyšla klasifikace pomocí RBF. Celková úspěšnost klasifikace vyšla vždy více než 60%. Průměrná hodnota u lineární i radiální SVM u klasifikace pomocí vybraných parametrů pak vyšla 56% a 65% u trénovacích dat, 61% a 68% u testovacích dat.

Pokud bychom porovnali dosažené výsledky s údaji z literatury, tak například u autora Tanga (dostupné v literatuře [39]) vyšla SVM pro fázi WAKE, REM a S1-S4 77,9%, tedy lépe než v této práci. Důvodem by mohl být výběr parametrů, jelikož autor použil parametry z vlnkové transformace, autoregresivní model a Hilbert-Huangovu transformaci. Také ovšem závisí na použitých signálech, jejich kvalitě a hodnocení. Při klasifikaci všech spánkových fází se klasifikační úspěšnost autorů odborných článků pohybuje v rozmezí 70 – 90 %. Pokud bychom se podívali na celkovou úspěšnost

klasifikace, pak u většiny případů vyšla hodnota kolem 70%. Důležité je však vzít v úvahu, že použité signály pro tuto diplomovou práci byly naměřeny u pacientů trpících poruchami spánku, což se mohlo projevit na dosažených výsledcích.

6. ZÁVĚR

Diplomová práce se zabývá automatickou klasifikací spánkových fází z polysomnografických dat. V první části je provedena literární rešerše zabývající se polysomnografií, předzpracováním, analýzou a metodami klasifikace. V praktické části je provedena analýza signálů a výpočet parametrů z časové a frekvenční oblasti z 30s epoch EEG, EMG a EOG signálů. Následně byla provedena statistická analýza pomocí Kruskal-Wallisova testu. Pomocí analýz bylo vybráno 23 parametrů. Analýze je věnovaná podstatná část práce, neboť výběr příznaků významně ovlivňuje celkovou přesnost klasifikace. Klasifikace byla provedena pomocí metody podpurných vektorů a křížové validace. Navržený klasifikační postup byl otestován na deseti signálech dostupných v databázi na ÚBMI. Na závěr je provedeno zhodnocení úspěšnosti klasifikace. Při samotné klasifikaci byla testována různá nastavení (standardizace, nfold). Vše bylo provedeno v programovém prostředí MATLAB.

Pokud bychom provedli srovnání s ostatními metodami klasifikace, můžeme říct, že metoda SVM je nejjednodušší a technicky nejméně náročnou s dostatečnou úspěšností klasifikace. Vylepšení bych poté viděla ve výpočtu více parametrů, a testování těchto parametrů pro dosažení lepších výsledků. Také by bylo vhodné nejprve detekovat K-komplexy a spánková vřetena, která jsou typická pro fázi N2. Další vylepšení by bylo možné pomocí detekce artefaktů, které se v signálech objevují, například při odlepení elektrod.

Klasifikace poté nejlépe vyšla pro N2 a nejhůře pro fázi N1. Úspěšnost klasifikace však ve všech případech vyšla přes 60%, což je považováno za dobrý výsledek.

Literatura

- [1] PHILIPS HEALTHCARE. *The Sleep Technician guide*. 2009.
- [2] LUKÁŠ, Karel a Aleš ŽÁK. *Chorobné znaky a příznaky 2: 35 vybraných znaků, příznaků a některých důležitých laboratorních ukazatelů v 32 kapitolách s prologem a epilogem*. Praha: Grada, 2011. ISBN 978-802-4737-287.
- [3] NEVŠÍMALOVÁ, Soňa a Karel ŠONKA. *Poruchy spánku a bdění*. Praha: Maxdorf, 1997. ISBN 80-858-0037-3.
- [4] HŮSKOVÁ, Jitka a Petra KAŠNÁ. *Ošetřovatelství - ošetřovatelské postupy pro zdravotnické asistenty: pracovní sešit II*. Praha: Grada, 2009. Sestra (Grada). ISBN 978-802-4728-.
- [5] ROZMAN, Jiří. *Elektronické přístroje v lékařství*. Praha: Academia, 2006. Česká matice technická (Academia). ISBN 80-200-1308-3.
- [6] NOVÁKOVÁ, Zuzana a Robert ROMAN. *Praktická cvičení z fyziologie*. Brno: Masarykova univerzita, 2007. ISBN 978-80-210-4391-6.
- [7] 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
- [8] DEUTSCHE GESELLSCHAFT FÜR SCHLAFFORSCHUNG UND SCHLAFMEDIZIN a HRSG. VON HARTMUT SCHULZ. *Kompendium Schlafmedizin: für Ausbildung, Klinik und Praxis*. 9. Ergänzungslieferung, März 2006. Landsberg/Lech: Ecomed, 1997. ISBN 3609766603.
- [9] KEMP, Bob. EDF-to-ASCII converter. Ver. 2004, Leiden. Počítačový program na převod signálů z EDF formátu do ASCII. 518 kB. Dostupné z <http://www.edfplus.info/>
- [10] 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.
- [11] ŠUŠMÁKOVÁ, K. Human Sleep and Sleep EEG. *Measurement Science Review*. 2004, roč. 4
- [12] SYNEK, Svatopluk a Šárka SKORKOVSKÁ. *Fyziologie oka a vidění*. Praha: Grada, 2004. ISBN 80-247-0786-1.
- [13] PŘIKRYLOVÁ, Lucie a Lenka SLEZÁKOVÁ. *Ošetřovatelství pro střední zdravotnické školy*. 2., dopl. vyd. Praha: Grada, 2014. Sestra (Grada). ISBN 978-80-247-4342-4.
- [14] PENHAKER, Marek a Martin AUGUSTYNEK. *Zdravotnické elektrické přístroje I*. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2013. ISBN 978-80-248-3107-7.

- [15] TROJAN, Stanislav. *Fyziologie a léčebná rehabilitace motoriky člověka*. 3., přeprac. a dopl. vyd. Praha: Grada, 2005. ISBN 80-247-1296-2.
- [16] KOZUMPLÍK, Jiří, Radim KOLÁŘ a Jiří JAN. *Číslíkové zpracování signálů v prostředí Matlab*. Brno: Vysoké učení technické, 2001. ISBN 80-214-1964-4.
- [17] JAN, Jiří. *Číslíková filtrace, analýza a restaurace signálů*. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002. ISBN 80-214-2911-9
- [18] RONZHINA, M. JANOUŠEK, O. KOLÁŘOVÁ, J. NOVÁKOVÁ, M. HONZÍK, P. PROVAZNÍK, I.: Sleep scoring using artificial neural networks. *Sleep Medicine Reviews*. 2012, vol. 16, issue 3, s. 251-263. DOI: 10.1016/j.smrv.2011.06.003. [cit. 2016-11-20] Dostupné z URL: <http://linkinghub.elsevier.com/retrieve/pii/S1087079211000700>
- [19] VURAL, Cabir 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. 2016-11-20] Dostupné z URL: <http://link.springer.com/10.1007/s10916-008-9218-9>
- [20] KOZUMPLÍK, J.: Zpracování biologických signálů. Přednáška. Brno: VUT v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012.
- [21] JAN, Jiří. *Číslíkové zpracování a analýza signálů: stručné skriptum*. Brno: Vysoké učení technické v Brně, 2010. ISBN 978-80-214-4018-0.
- [22] KRAJČA, Vladimír a Jitka MOHYLOVÁ. *Číslíkové zpracování neurofyziologických signálů*. V Praze: České vysoké učení technické, 2011. ISBN 978-80-01-04721-7.
- [23] ŠÍMA, Jiří a Roman NERUDA. *Teoretické otázky neuronových sítí*. Praha: Matfyzpress, 1996. ISBN 80-85863-18-9.
- [24] KOZUMPLÍK, J.: *Umělá inteligence v medicíně*, skripta předmětu Umělá inteligence v medicíně. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2007.
- [25] KOZUMPLÍK, J. Analýza biologických signálů, (Rozpracovaná skripta), VUT v Brně, 2011.
- [26] KOZUMPLÍK, J. Umělá inteligence v medicíně: Shluková analýza. [online]. [cit. 2016-11-22]. Dostupné z: https://www.vutbr.cz/elearning/file.php/123626/prednasky/Prednasky_12_13/AUI_N_02_shlukova_analyza.pdf
- [27] HONZÍK, P.: *Strojové učení*, skripta předmětu Strojové učení. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2006.
- [28] MELOUN, Milan, Jiří MILITKÝ a Martin HILL. *Počítačová analýza vícerozměrných dat v příkladech*. Praha: Academia, 2005. ISBN 80-200-1335-0.

- [29] *Matematická biologie* [online]. Brno: Institut biostatistiky a analýz Masarykovy univerzity [cit. 2016-11-23]. Dostupné z: <http://portal.matematickabiologie.cz/>
- [30] PAVLÍK, Tomáš a Ladislav DUŠEK. *Biostatistika*. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-782-6.
- [31] BAKYTOVÁ, H., UGRON M. a O. KONŠTĚKOVÁ. *Základy štatistiky*. 1. vyd. Bratislava: Alfa, 1975.
- [32] STEINWART, Ingo. a Andreas. CHRISTMANN. *Support vector machines*. New York: Springer, c2008. ISBN 978-0-387-77241-7.
- [33] WANG, Lipo. *Support vector machines: theory and applications*. Berlin: Springer, 2005. ISBN 978-3-540-24388-5.
- [34] B. Efron, G. Gong, A Leisurely Look at the Bootstrap, the Jackknife, and Cross-Validation, 1983
- [35] GEISSER, Seymour. *Predictive inference: an introduction*. New York: Chapman & Hall, 1993. ISBN 0-412-03471-9.
- [36] MCLACHLAN, Geoffrey J., Kim-Anh DO a Christophe AMBROISE. *Analyzing microarray gene expression data*. Hoboken, N.J.: John Wiley, c2004. Wiley series in probability and statistics. ISBN 0-471-22616-5.
- [37] BISHOP, CH. M. *Neural networks for pattern recognition*. New York: Oxford Univ. Press, 1996., 482 s. ISBN 0-19-853864-2
- [38] ŠNOREK, M. *Neuronové sítě a neuropočítače*. Vyd. 1. Praha: ČVUT, 2002. 156 s., ISBN 80-01-02549-7.
- [39] 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.

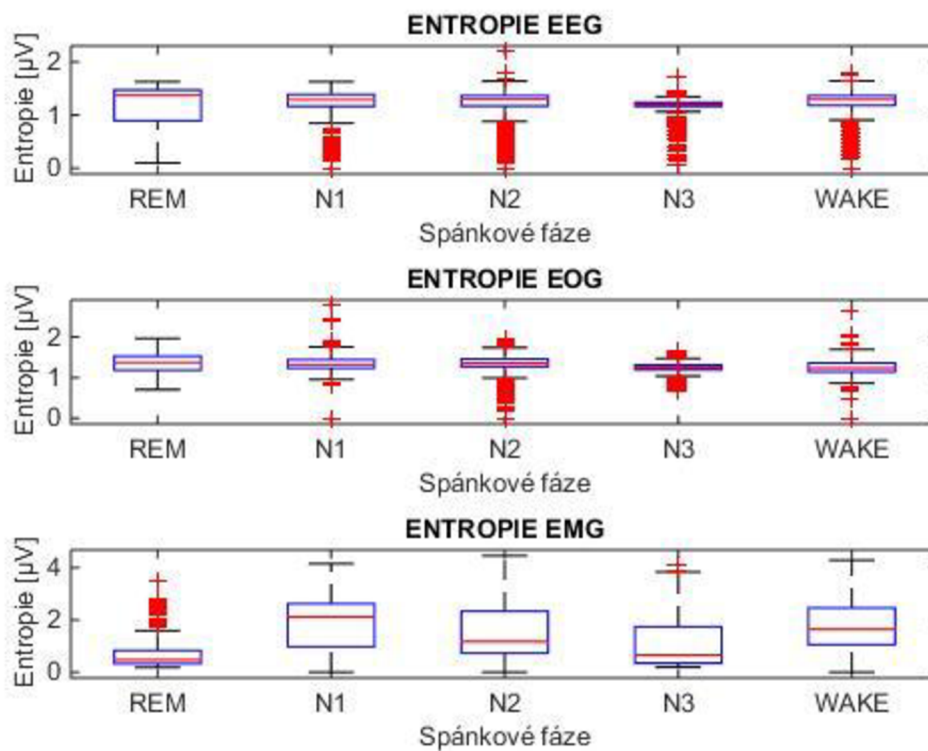
Seznam symbolů, veličin a zkratek

REM	rapid eye movement
NREM	non rapid eye movemnt
EEG	elektroencefalografie
EOG	elektrookulografie
EMG	elektromyografie
EKG	elektrokardiografie
R&K	metoda Rechtschaffena a Kalese
AASM	standard American Academy of Sleep Medicine
Hz	hertz
MT	movement time
DFT	diskrétní Fourierova transformace
PSG	polysomnografie
MJ	motorická jednotka
W	fáze wake
NREM	fáze nonrem (z angl. non rapid eye movement)
REM	fáze rem (z angl. rapid eye movement)
mV	milivolt
cm	centimetr
AgCl	chemická sloučenina chlorid stříbrný
ORL	otorhinolaryngologie
FIR	filtr s konečnou impulsní charakteristikou
FT	Fourierova transformace
STFT	krátkodobá Fourierova transformace
WT	vlnková transformace
μ V	mikrovolt
SVM	support vector machine
RBF	radialní bázová fáze

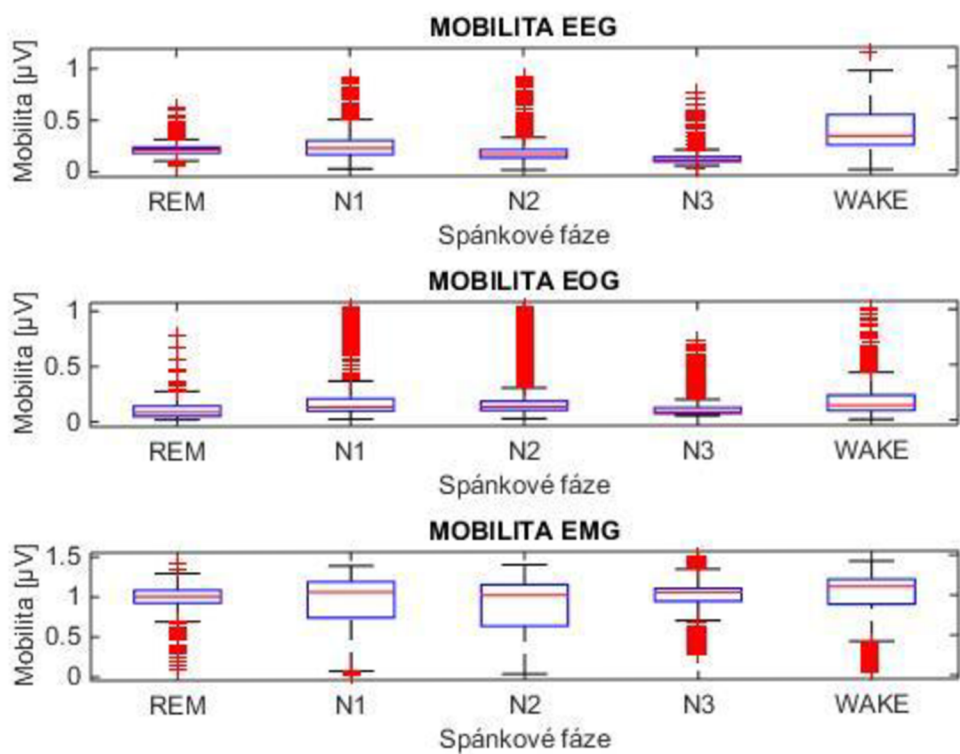
Seznam příloh

PŘÍLOHA A

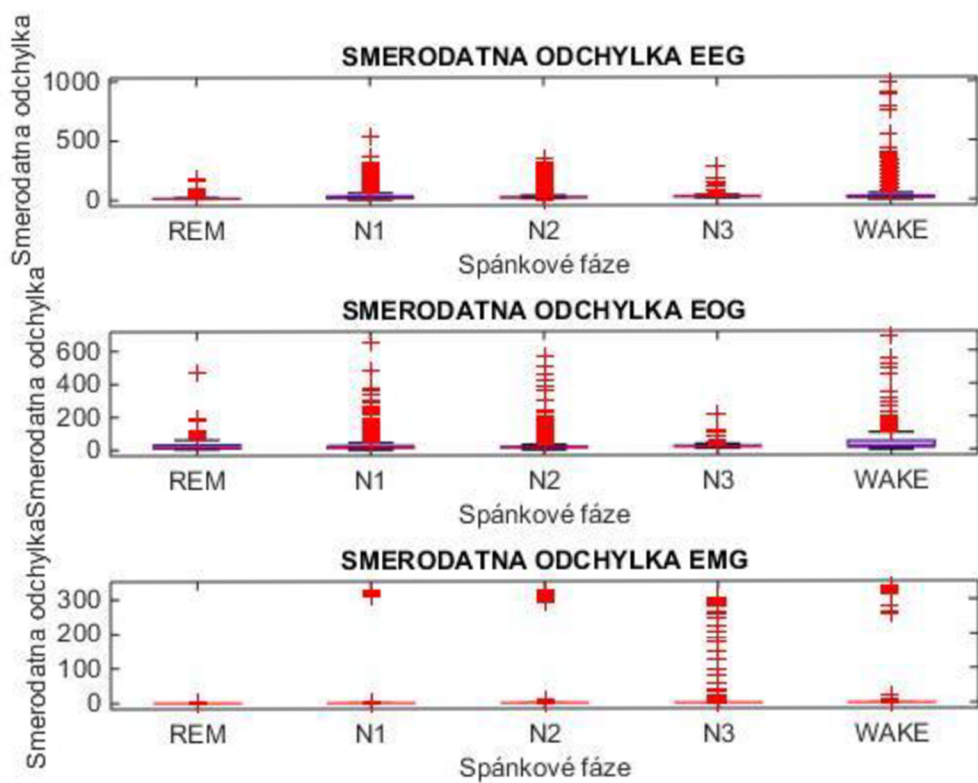
Krabicové grafy vypočítaných parametrů v časové a frekvenční oblasti




Obrázek 1 Entropie signálů



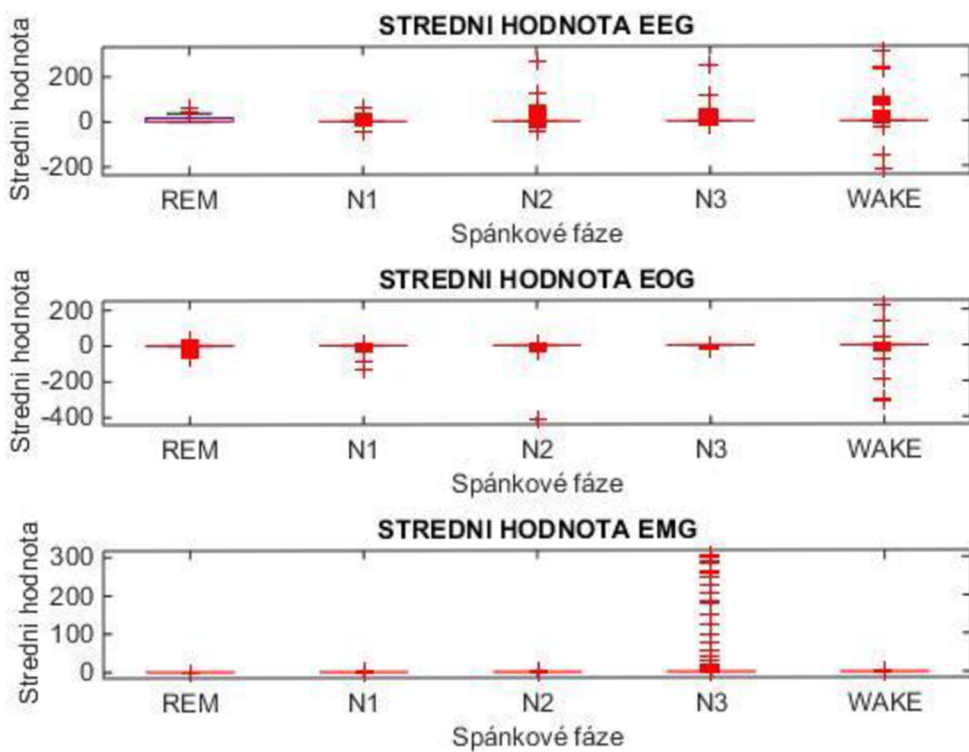
Obrázek 2 Mobilita signálů



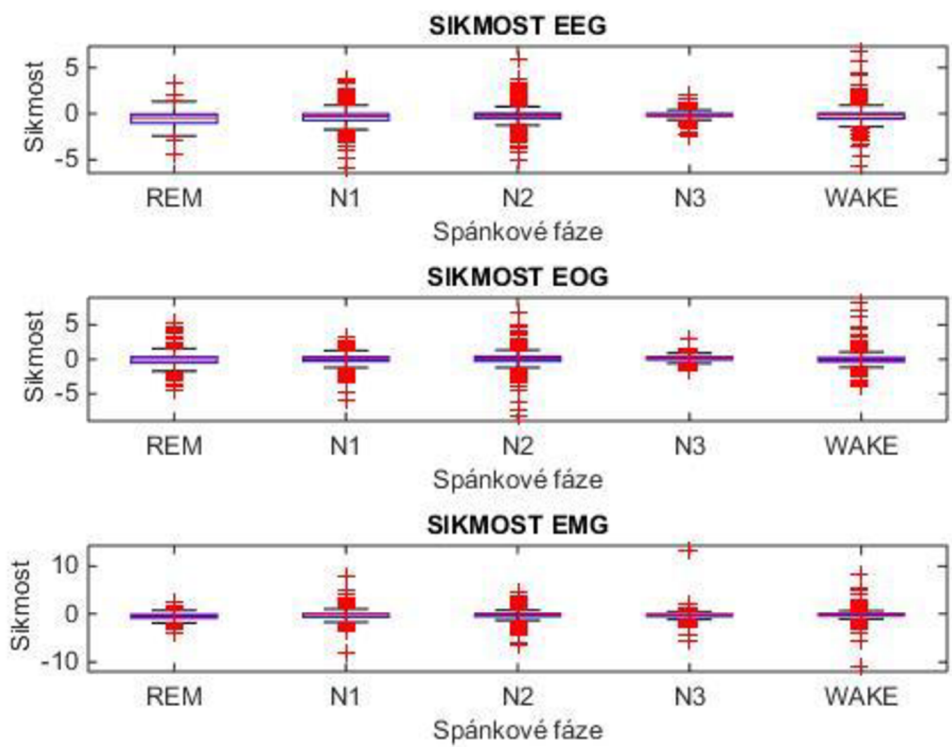
Obrázek 3 Směrodatná odchylka signálů



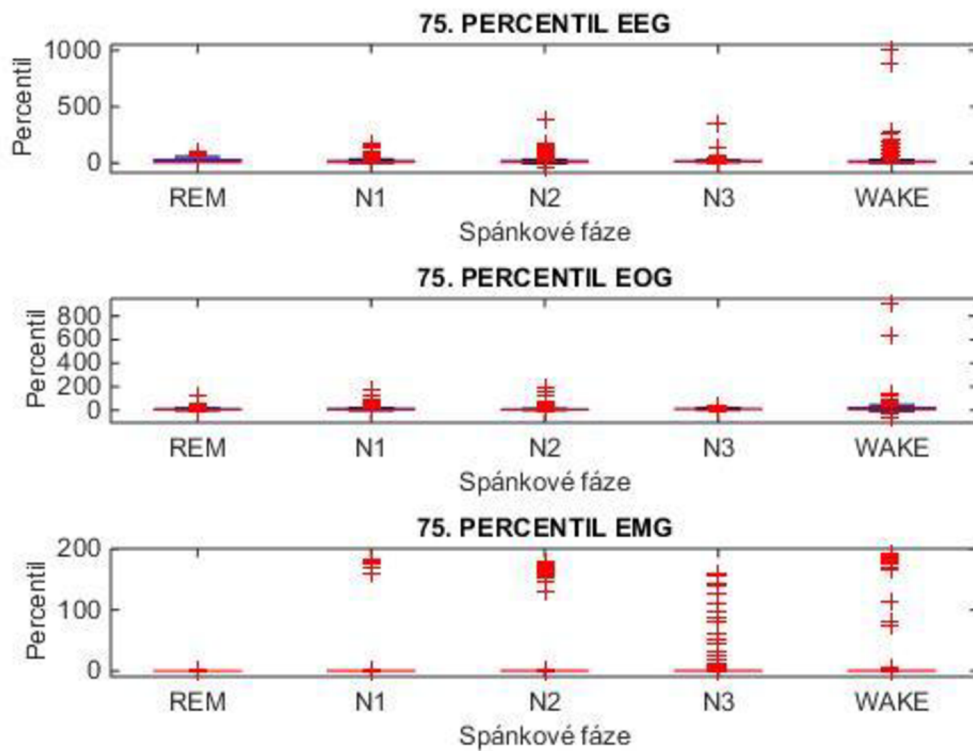
Obrázek 4 Složitost signálů



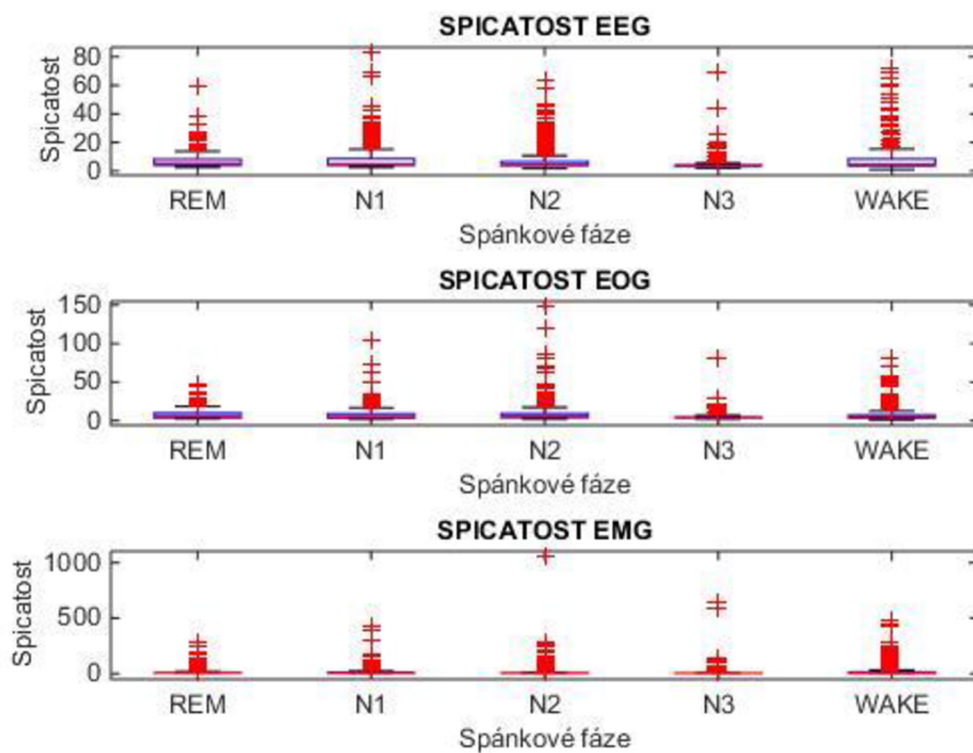
Obrázek 5 Střední hodnota signálů



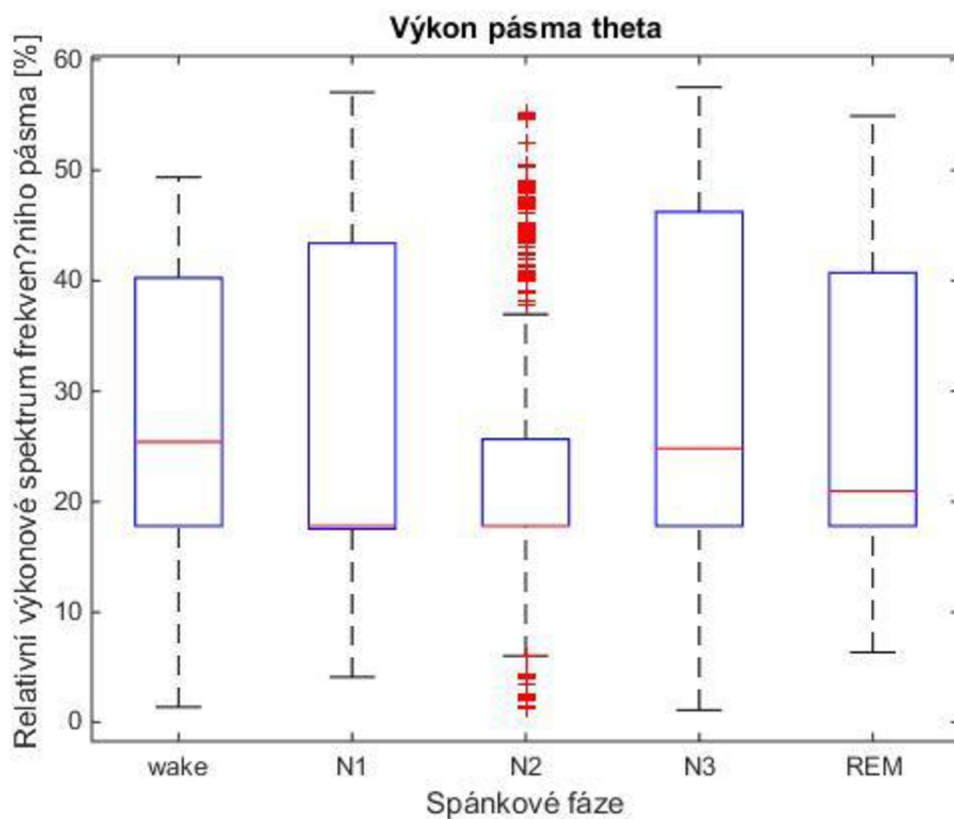
Obrázek 6 Šikmost signálů




Obrázek 7 75. percentil signálů



Obrázek 8 Špičatost signálů



Obrázek 9 Relativní výkonové spektrum pásma theta



Obrázek 10 Relativní výkonové spektrum pásma theta

