



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

AUTOMATIC SLEEP SCORING

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Miroslav Schwanzer

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2019

Diplomová práce

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

Ústav biomedicínského inženýrství

Student: Bc. Miroslav Schwanzer

ID: 77877

Ročník: 2

Akademický rok: 2018/19

NÁZEV TÉMATU:

Automatická klasifikace spánkových fází

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: 4.2.2019

Termín odevzdání: 17.5.2019

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 klasifikací spánkových fází na základě polysomnografických signálů. Pro vybrané signály byla provedena analýza a selekce příznaků v časové oblasti a ve frekvenční oblasti. Příznaky ke klasifikaci byly získány ze signálů EEG, EOG a EMG. Jako klasifikátory byly použity klasifikační modely typu K-NN, SVM, a umělé neuronové sítě. Úspěšnost klasifikace se liší podle použité metody a rozdělení skupin. Nejlepších výsledků dosahovala klasifikace mezi stavy bdělosti, fáze REM a N3, a to za pomoci neuronové sítě. Zde bylo dosaženo celkové úspěšnosti 93,1 %.

KLÍČOVÁ SLOVA

Elektroencefalografie (EEG), Výkonová spektrální hustota (PSD), Umělá neuronová síť, Polysomnografie (PSG), Automatická klasifikace, klasifikátor K-NN, klasifikátor SVM.

ABSTRACT

This master thesis deals with classification of sleep stages on the base of polysomnographic signals. On several signals was performed analysis and feature extraxtion in time domain and in frequency domain as well. For feature extraxtion was used EEG, EOG and EMG signals. For classification was selected classification models K-NN, SVM and artifical neural network. Accuracy of clasifation is different depending on used method and spleep stages split. The best results achieved classification among stages Wake, REM, and N3, with neural network usage. In this case the succes was 93,1 %.

KEYWORDS

Electroencephalography (EEG), Power spectral density (PSD), Artifical neural network, Polysomnography (PSG), Automatical classification, K-NN classifier, SVM classifier.

Bibliografická citace:

SCHWANZER, M. *Automatická klasifikace spánkových fází*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2019. 56 s. Vedoucí práce Ing. Marina Ronzhina Ph.D.

Prohlášení

„Prohlašuji, že svou závěrečnou práci na téma *Automatická klasifikace spánkových fází* jsem vypracoval samostatně pod vedením vedoucího 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 neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si 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.

V Brně dne **16. května 2019**

.....
podpis autora

Poděkování

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

V Brně dne **16. května 2019**

.....
podpis autora(-ky)

OBSAH

Úvod.....	1
1 Polysomnografie	2
1.1 EEG aktivita.....	3
1.2 Spánková stádia	6
2 Základní rozdělení signálu	8
2.1 Deterministické signály.....	8
2.2 Stochastické signály.....	8
2.3 Elektroencefalografické signály.....	9
2.3.1 Snímání signálu EEG	9
2.4 EOG signály	11
2.5 EMG signály	11
3 Postup automatické klasifikace spánkových fází z patientských dat.....	12
3.1 Segmentace	12
3.2 Výpočet příznaků	12
3.2.1 Analýza EEG signálu	13
3.2.2 Analýza v časové oblasti	13
3.2.3 Analýza ve frekvenční oblasti.....	15
3.3 Časově-frekvenční analýza signálů	18
3.4 Spektrální entropie.....	19
4 Klasifikační modely	20
4.1 Popis a metody klasifikace	20
4.2 K-NN (K-nejbližších sousedů)	20
4.3 SVM (metoda podpůrných vektorů)	21
4.4 Neuronové sítě.....	22
4.4.1 Popis funkce.....	22
4.4.2 Vícevrstvé neuronové sítě	24
4.4.3 Architektura neuronových sítí - topologie	25
5 Analýza polysomnografických signálů.....	30
5.1 Popis dat	30
5.2 Výpočet příznaků z průběhu EEG, EOG, EMG	32
5.2.1 Příznaky v časové oblasti.....	33
5.2.2 Příznaky ve frekvenční oblasti	35
5.2.3 Bodové zobrazení	37
5.2.4 Vyhodnocení klasifikačních výsledků.....	38
6 Klasifikace analyzovaných PSG signálů	39
6.1 Klasifikace pomocí neuronové sítě	40
6.1.1 Volba trénovacích dat.....	40
6.1.2 Návrh neuronové sítě pro klasifikaci.....	40
6.1.3 Trénování neuronové sítě	41
6.2 Klasifikace K-NN klasifikátorem	46
6.3 Klasifikace SVM klasifikátorem.....	47
7 ZÁVĚR	49

Literatura.....	51
Seznam symbolů, veličin a zkratk	54
8 Příloha	55

SEZNAM OBRÁZKŮ

Obr. 1 Ukázka rozkladu EEG signálu na jednotlivá pásma v časové oblasti.....	3
Obr. 2 Vyobrazení spánkových fází pomocí výskytu v jednotlivých frekvenčních pásmech a jejich možná prolínání (vztahy mezi spánkovými epochami a EEG rytmy)	5
Obr. 3 Rozmístění elektrod podle mezinárodního 10-20 systému. [13]	10
Obr. 4 Diagram navrhovaných metod vedoucích ke klasifikaci EEG signálu	13
Obr. 5 Grafické znázornění získání periodogramu Welchovou metodou převzato z [27]	18
Obr. 6 Ukázka výkonové spektrální hustoty získané pomocí Welchova modifikovaného periodogramu.	18
Obr. 7 Spektrogramy získané z krátkodobých spekter signálu EEG pro fázi W a N3, a) pro fázi wake jsou vidět vysoké hodnoty krátkodobých která pokrývají širší rozpětí frekvencí (červená oblast), b) u spánkové fáze N3 lze vidět, že červená oblast zasahuje jen nižší kmitočty oproti fázi wake	19
Obr. 8 Ukázka a popis umělého neuronu [26]	23
Obr. 9: Ukázka přenosové funkce a) logaritmická sigmoida b) tangens sinoida c) jednotkový skok d) lineární funkce (převzato z [20])	24
Obr. 10 Architektura dopředné neuronové sítě [26]	25
Obr. 11 Schéma učení neuronu pomocí metody bez učitele.....	26
Obr. 12 Schéma učení neuronu pomocí metody s učitelem.....	27
Obr. 13 Zobrazení krabicových grafů pro porovnání střední hodnoty jednotlivých spánkových fází	34
Obr. 14 Graf znázorňující rozložení příznaku mobilitu pro EEG signál v jednotlivých spánkových fázích.....	34
Obr. 15 Zobrazení krabicových grafů pro porovnání spektrální entropie jednotlivých spánkových fází	36
Obr. 16 Zobrazení krabicových grafů pro porovnání relativní PSD jednotlivých spánkových fází ve vybraném pásmu delta	36
Obr. 17 Zobrazení krabicových grafů pro porovnání relativní PSD jednotlivých spánkových fází ve vybraném pásmu alfa	37
Obr. 18 Ukázka rozložení závislosti shluků příznaků mobilita EEG a komplexnost mezi spánkovými fázemi W a N1-N2-N3.	37
Obr. 19 Diagram postupu při návrhu, trénování a procesu testování neuronové sítě se zpětným šířením chyby	40
Obr. 20 Vizualizace simulace trénování sítě pro 2 skryté vrstvy (Matlab Neural Network toolbox), a s třemi výstupními neurony pro klasifikaci do třech fází.....	43
Obr. 21 Znázornění matice záměn získané vykreslením výsledků klasifikace v programu Matlab	43

Obr. 22 Znázornění závislosti počtu neuronů pro 2 skryté vrstvy neuronové sítě a procentuální úspěšnost její klasifikace do tří fází W, REM, N3 na typu zvoleného trénovacího algoritmu	44
Obr. 23 Graf závislosti procentuální úspěšnosti klasifikace jednotlivých trénovačích funkcí do tří fází W, REM, N3 a spánek na počtu neuronů.....	45
Obr. 24 Graf závislosti procentuální úspěšnosti klasifikace jednotlivých trénovačích funkcí při klasifikaci do dvou fází bdělost a spánek na počtu neuronů.	45
Obr. 25 Znázornění procentuální úspěšnosti klasifikace do skupin W, REM, N3 v závislosti na počtu sousedů pro vybrané klasifikační metriky.....	46
Obr. 26 Znázornění procentuální úspěšnosti klasifikace do skupin W, REM+N1+N2+N3 (bdění a spánek) v závislosti na počtu sousedů pro vybrané klasifikační metriky.....	47

SEZNAM TABULEK

Tabulka 1 Přehled rozdělení energetických pásem EEG signálu v porovnání se stavem bdělosti.....	3
Tabulka 2 Počet epoch v jednotlivých spánkových fázích získané ze signálu pro zpracování EEG.....	32
Tabulka 3 Přehled fází a jejich vhodnosti pro klasifikaci podle statistického vyhodnocení pro získané příznaky v časové oblasti	33
Tabulka 4 Přehled fází a jejich vzájemné vhodnosti pro klasifikaci podle statistického vyhodnocení pro získané příznaky ve spektrální oblasti .	35
Tabulka 5 Znázornění schématu matice záměn.....	39
Tabulka 6 Příklad binárního kódování výstupu pro případ 3 výstupních neuronů (kódování jednotlivých spánkových fází pomocí 1 a 0)	40
Tabulka 7 Přehled optimalizačních metod a jejich parametrů pro síť typologie se zpětným šířením chyby	42
Tabulka 8 Tabulka výsledků klasifikace pro určené spánkové fáze klasifikátorem K-NN.....	47
Tabulka 9 Tabulka výsledků klasifikace pro určené spánkové fáze W , REM, N3 pomocí klasifikátoru SVM	48
Tabulka 10: Přehled výsledků klasifikace do tří spánkových fází W/REM/N1-N2-N3 a 15 vstupních příznaků získané pomocí neuronové sítě.	55
Tabulka 11 Tabulka výsledků klasifikace pro určené spánkové fáze klasifikátorem K-NN s vybranými typy metrik	56

ÚVOD

Dnešní doba klade na jednotlivce velké nároky, ať již vlivem vývoje prostředí nebo pracovního vytížení, což může vést často k poruchám zdravého spánku a neblaze se projevit v přirozeném spánkovém rytmu, potažmo v průběhu jednotlivých spánkových fázích. Z tohoto důvodu se stále více rozvíjí různé metody, díky nimž je možné dané poruchy analyzovat a rozlišovat. Bavíme-li se zde o analýze polysomnografických (PSG) signálů, především jsou pak ve středu zájmu této práce signály elektroencefalografické (EEG), elektrookulografické (EOG) a elektromyografické (EMG).

Klasická klasifikace spánkových PSG byla donedávna pouze v rukou odborníků, resp. lékařů. To však v sobě přináší určité nevýhody. PSG se skládá z akvizice několika druhů elektrických biosignálů, které bývají zpravidla za účelem klasifikace rozděleny na malé úseky, přičemž jednotlivé segmenty mívají zpravidla délku 20-30 sekund. V případě manuálního skórování prováděné lékařem na několikahodinovém záznamu, který se zpravidla pohybuje v rozpětí osmihodinového spánku, je tento proces ve finále časově náročný. A co je v tomto případě důležité je fakt, že v závislosti na čase také klesá lidská pozornost a s tím i efektivita klasifikačního procesu.

S vývojem algoritmizačních disciplín a metod umělých neuronových sítí se začalo ukazovat, že je výhodné podobně náročný procesy jako klasifikace projevů během spánku extrahovaných z biologických signálů zautomatizovat, a tím vyhodnocování podstatně zkrátit.

Obsahem této práce je teoretický popis průběhu jednotlivých spánkových fází především s odkazem na nové standardy AASM (American Academy of Sleep Medicine), které modifikují dosud využívané a také jediné standardy dle modelu R&K, sloužící ke skórování časových průběhů EEG signálů. Dále je zde uvedena teorie výpočtů parametrů v časové a ve frekvenční oblasti, které jsou poté prakticky ověřeny během analýzy reálných signálů získaných z databáze FNUSA (Fakultní nemocnice u sv. Anny v Brně) za pomoci parametrů v časové oblasti, a také parametrů z frekvenční oblasti, resp. výkonové spektrální hustoty. Ze získaných hodnot byly extrahovány příznaky EEG, EOG a EMG vhodné k následné klasifikaci na základě spánkových epoch a dále navržen klasifikátor za pomoci umělé neuronové sítě a dále klasifikátoru typu K-NN a SVM.

1 POLYSOMNOGRAFIE

Polysomnografie je metodologie k definování bdělých a spánkových stavů ze zkoumaných signálů EEG. Ke studiu spánkových fází jsou využívána polysomnografická (PSG) měření, během nichž probíhá současně měření více biologických signálů na několika částí těla během spánku. U běžných stavů bdělosti a spánku se nejčastěji využívá měření EMG, EKG, EOG, a hlavně EEG signály. Snímání signálů probíhá za pomoci elektrod, které jsou připojeny ke skalpu hlavy, na obličeji v okolí očí a na těle.

Co se týče vizuální klasifikace PSG signálů, existují dvě možnosti, jak k hodnocení přistupovat. Do roku 2007 byl využíván pro spánkovou klasifikaci standard, který publikovali a zavedli pánové Rechtschaffen a Kales (R&K) v roce 1968. Od roku 2007 se pro klasifikaci PSG začlenily nové standardy AASM (The American Academy of Sleep Medicine).

AASM modifikovala standardní rozdělení pro spánkovou klasifikaci zavedenou R&K a rozvinula je do nových standardů týkajících se jednak terminologie, ale také zaznamenávacích metod a hodnocení spánkových fenoménů, sepsaných jako "Manual of the Scoring of sleep and Associated Events". Dokument obsahuje referenční pravidla k vyhodnocování polysomnografických signálů a pro vizuální klasifikaci spánkových fází. Manuál také definuje standardy pro umístění snímacích elektrod a vhodné parametry digitalizace signálu. Tato klasifikace nahradila pravidla R&K. První majoritní rozdíl mezi starší metodou (R&K) a novými standardy (AASM) je celkový počet spánkových epoch. AASM zavádí pouze pět epoch oproti předchozím šesti a to následující: Bdělý stav, který je označován jako fáze Wake (W), dále spánkové fáze NREM1, NREM2, NREM3 a REM (rapid eye movement) je uváděná jako fáze R. U standardu AASM tak došlo ke sloučení spánkových fází, které byly předtím rozděleny mezi fáze S3 a S4, do fáze NREM3 (N3), fázím S1 a S2 odpovídají stádia s pojmenováním NREM1 (N1), NREM2 (N2). [3]

Pro korektní klasifikaci musí být podle AASM zaznamenány např. v případě EEG signálů aktivity minimálně z tří různých míst, a to z frontální, centrální a okcipitální oblasti na hlavě, s nastavením zohledňující frekvenční pásmo se kterým budeme chtít pracovat (vzorkovací frekvence) a dále také amplituda signálu.

1.1 EEG aktivita


Elektrická aktivita mozku vykazuje rytmickou aktivitu o různých frekvencích. Podle toho rozlišujeme vlny do několika základních pásem: delta (0,3-4 Hz), vlny pásma theta (4-7 Hz), aktivita alfa (8-13 Hz) a směrem k vyšším frekvencím rozlišujeme vlny beta (13-30 Hz) a gamma (30-50 Hz) (obr. 1).

Tabulka 1 Přehled rozdělení energetických pásem EEG signálu v porovnání se stavem bdělosti

Rytmus	Frekvenční rozsah	Popis stavu
Delta	0,5-4 Hz	Bezesný spánek
Theta	4-7 Hz	Ospalost, otupělost
Alfa	8-13 Hz	Relaxace spojená se zavřenými očima
Beta	13-30 Hz	Bdělost, pozornost, intenzivní mentální aktivita
Gamma	> 30	Stav meditace, transu

AASM stanovuje začátek a konec jednotlivých spánkových epoch a popisuje základní charakteristiky různých variant spánkových a bdělých epoch jako REM, SEM (angl. slow eye movement), alfa rytmus, vertex sharp wave, spánková vřetena, K-komplexy a pomalá vlnová aktivita (Tabulka 1).

Zobrazení jednotlivých EEG pásem



Obr. 1 Ukázka rozkladu EEG signálu na jednotlivá pásma v časové oblasti

Delta rytmus

Delta rytmus lze zachytit ve frekvenčním pásmu 0,3-4 Hz s amplitudou o velikosti 75–210 μV . Jedná se o rytmus typický pro hluboký spánek nebo ho je možné zaznamenat také při stavech transu a hypnózy. Za normálního bdělého stavu se téměř vůbec nevyskytuje. Ke zvýšení delta aktivity však může dojít v důsledku patologických změn mozku nebo také během řešení nějakého problému. Zde platí, že čím je daný problém složitější, tím dochází k větším změnám v oblasti delta aktivity. [18]

Theta rytmus

Theta rytmus se vyskytuje ve frekvenčním pásmu od 4-8 Hz, s amplitudou 5-100 μV . Dochází zde k výraznému útlumu všech funkcí, především myslí, která nereaguje na téměř žádné smyslové podněty. Projevem aktivity je se stav ospalosti, usínání, nebo hlubokého uvolnění. Při usínání pak přechází v delta aktivitu. Patologická je theta aktivita jako projev mozkové dysfunkce. U zdravých jedinců je výskyt theta vln převážně v centrální, spánkové (temporální) a temenní (parientální) oblasti. Theta aktivita se také objevuje při nadměrné představivosti, fantazii, zvýšené kreativitě nebo vizualizaci myšlenek a pojí se často se živými vzpomínkami. Pokud se theta aktivita vyskytuje v temporální oblasti, bývá to často převážně u starší části populace. V normálním bdělém stavu je přítomna jen v malém množství. [18]

Alfa rytmus

Alfa aktivity má frekvenci pohybující se v rozmezí 8-13 Hz a amplituda těchto vln kolísá v rozmezí 5-100 μV , jako běžné jsou považovány amplitudy 20-80 μV . Ve stavu bdělosti se maxima vln alfa nachází hlavně nad zadními oblastmi obou hemisfér (okcipito-temporálními). Nejvýraznější je ve stavu tělesné a psychické relaxace a při zavřených očích v bdělém stavu, tedy stavu duševního i tělesného uvolnění, kdy dochází k poklesu soustředění, snížení ostatní mozkové aktivity. Je blokována v důsledku otevření očí a při náhlém mentálním soustředění se na nějaký problém, což bývá označováno jako tzv. alfa atenuační reakce nebo alfa desynchronizace, alfa rytmus je zde nahrazen vlněními beta nebo gamma, které dosahují vyšších frekvencí, ale nižší amplitudou. Znovu se objevuje při opětovném zavření očí. Útlum nastává také během emočního napětí, nebo ospalostí. Alfa rytmus je především aktivitou optického analyzátoru. Alfa aktivita je také spojována s vizuálními funkcemi, kdy nedochází k vizuálním vstupům, popř. během spánkové fáze REM. Amplituda alfa vln se ve většině případů zvyšuje při hypoventilaci. Zpravidla aktivita těchto vln s přibývajícím věkem klesá. U lidí nemocných, vystavených dlouhodobému stresu či závislých na alkoholu a drogách je aktivita alfa méně výrazná než u zdravých. [18]

Beta rytmus

Vlnění spadá do frekvenčního rozsahu 13–30 Hz, obvykle se pak vyskytuje v nižších rozmezech 18–25 Hz. Velikosti amplitud těchto signálů jsou při měření ve skalpovém EEG nízké v rozmezí 20–30 μV , jsou tedy silně tlumeny, přičemž amplituda bývá nižší než 20 μV . Trvání jednotlivých vln je přibližně 40–50 ms.

Beta rytmy dosahují u člověka maxim nad frontálními až fronto centrálními laloky mozku, ale vyskytovat se může také v ostatních mozkových oblastech, kde ovšem aktivita, zvláště v zadních oblastech ubývá. Výskyt beta aktivity je charakteristický především pro centrální nervový systém, tedy poukazuje na zvýšenou pozornost nebo mentální činnost, reakce na vnější podněty s otevřenými očima, a dále u logicko-analytického myšlení. Beta aktivita je také spjata s pocitem neklidu, hněvu a strachu. Poměr beta aktivity se postupně zvyšuje také s věkem a u žen bývá ve větším zastoupení než u mužské části populace. Značný podíl beta vln se může objevit při medikamentózním ovlivnění (např. barbituráty).

Polysomnografická měření jsou založena na předpokladech, že určité vzorce, které lze běžně zachytit ve spánku, se liší od vzorců typických pro stav bdělosti. Pomalé vlny theta a delta se zpravidla během spánku vyskytují v široké distribuci. Lépe bývají prokreslené nad zadními oblastmi, rychlejší, nižší, více asynchronní a méně perzistující v povrchních stádiích NREM spánku než ve stádiích hlubších [6]. Obrázek níže (obr. 2) zachycuje rozdělení jednotlivých frekvenčních pásem, a jejich výskyt v závislosti na průběhu spánkových fází, které jsou detailněji popsány v následujícím textu.

Delta (0,5 - 4 Hz)	Theta (4 - 8 Hz)	Alfa (8 - 13 Hz)	Beta (13 - 30 Hz)
fáze N3	fáze N1	fáze bdění	
	fáze N1		
	fáze N2	fáze REM	

Obr. 2 Vyobrazení spánkových fází pomocí výskytu v jednotlivých frekvenčních pásmech a jejich možná prolínání (vztahy mezi spánkovými epochami a EEG rytmy)

1.2 Spánková stádia

Normální spánek se skládá zpravidla ze 4–6 cyklů NREM stádií, které se střídají s REM fází každých 90–120 min. Graficky lze poté jednotlivé spánkové cykly vyobrazit v podobě hypnogramu. Dle AASM standardu rozeznáváme následující fáze:

W (wake)

Fáze (bdělý stav) – jsou charakteristické pro vlny s nízkým napětím (10-30 μV), pokrývají frekvenční pásmo 8–13 Hz (alfa pásmo), přičemž je závislá na otevření očí, kdy je atenuována. Mohou také obsahovat aktivitu svalů (EMG) o frekvencích větších jak 30 Hz. Vyskytují se převážně v oblastech okcipitálních. Počáteční fáze stádia N1

N1 (NREM 1)

Přechodová fáze mezi bdělostí a spánkem, ačkoliv se již považuje za spánkovou fázi. Tvoří zhruba 5-10 % celkového spánkového stádia. Pro tuto fázi platí frekvenční pásmo 4–7 Hz (theta pásmo),

N2 (NREM2)

Fáze lehkého spánku, která trvá zhruba 30–60 minut. Jedná se většinou o delta a theta rytmi proložené K-komplexy a spánkovými vřeteny. Lokalizovat lze v centrální, frontální a okcipitální oblasti. Tvoří 50 % celkového spánkového stádia, malá amplituda

- Přechodové stádium k fázi W
 - **K-komplex**
 - **Spánková vřetena:** frekvenční pásmo 9–14 Hz (sigma aktivita), velikost 10 μV Typická oblast výskytu je centrální a frontální.

N3 (NREM3)

Fáze hlubokého spánku (Slow wave sleep) s dobou trvání kolem 20-40 minut (zhruba 20% spánkové fáze). Kombinuje epochy S3 a S4 podle R&K. Jedná se o přechodové stádium k fázi R. Pro stádium N2 je typický rostoucí výskyt delta aktivity (frekvenční rozsah 0,5 – 3 Hz) s amplitudami do 75 μV . Zaujímá zhruba 20-50 % z celkového spánkového stádia. Lokalizovat lze v oblastech frontálních a centrálních.

R (REM)

Mluvíme zde o fázi, při níž se vyskytují sny. Frekvenční rozsah 4–7 Hz (alfa pásmo) tvoří 20–25 %, uvádí se dokonce až 50 % každé epochy celkového spánkového stádia. Tyto alfa rytmy lze zaznamenat nejčastěji v okcipitální oblasti hlavy. Jedná se o vlny ostrých až trojúhelníkových tvarů se zubovitým průběhem. Řadí se mezi nízkonapěťové vlny s výskytem rychlých očních pohybů.

Podle rozdělení AASM jednotlivé spánkové fáze dané epochami odpovídají určitému frekvenčnímu pásmu EEG aktivity, přičemž se pásma mohou mnohdy překrývat navzájem (Obr. 2).

Důležitou charakteristikou pro rozpoznání spánkového stádia se zdá být dominantní přítomnost frekvenční pásma 0,5 – 3 Hz, tedy delta aktivity, která se v EEG vyskytuje v průběhu klidové fáze a je jen velmi malá ve stádiích bdělosti a aktivního spánku REM. Tímto lze zařadit delta aktivitu mezi stěžejní příznaky rozpoznání spánkových stádií. Naopak hůře rozlišitelné jsou stádia přechodová, převážně mezi stavy REM a NREM1 lze očekávat horší rozlišitelnost. [11]

2 ZÁKLADNÍ ROZDĚLENÍ SIGNÁLU

Signály lze rozčlenit podle několik popisných znaků. Kromě základních typů dělení na spojité a diskrétní jsou často používány rozdělení signálů na deterministické a stochastické, přičemž jejich posuzování vychází z vlastností vyplývajících z jejich původu.

2.1 Deterministické signály

Pokud mluvíme o signálech, které jsou popsány funkcemi a jejich posloupnostmi, jejichž každou hodnotu lze pro vybraný okamžik přesně vypočítat, tedy existují pro jejich hodnoty matematický výraz nebo vzorec, potom se tyto signály označují jako deterministické. [14]

2.2 Stochastické signály

Signály, u kterých nelze přesně určit, jakých hodnot budou nabývat, a jejich časový průběh není možné popsat matematickými výrazy, pak tyto signály neoznačujeme jako deterministické, ale mluvíme o náhodných signálech, tedy signálech stochastických. Tyto signály jsou zpravidla generovány fyzikálním pochodem, který je ovlivňován náhodnými podmínkami a okolnostmi při jejich produkci. Do kategorie stochastických signálů řadíme také signály deterministické, které jsou ovšem zarušeny nedeterministickým šumem. Náhodné signály jsou popisovány pravděpodobnostními nebo statistickými metodami. Hodnoty nedeterministických signálů interpretujeme jako soustavu náhodných proměnných, nebo popisujeme průběh signálů statistickými charakteristikami určenými z jeho časového průběhu. Jako statistické charakteristiky jsou často využívány např. střední hodnota, rozptyl, autokorelační funkce nebo spektrální hustota. V praxi však zpravidla získáváme jedinou realizaci náhodného procesu konečné délky, a tak není možné určit přesné hodnoty charakteristik, které bychom získali, případně znalosti několika realizací procesu, a pro nekonečně dlouhé intervaly pozorování. Hodnoty charakteristik lze tedy pouze odhadnout s určitou přesností. Charakteristiky takovýchto signálů se tím chovají jako náhodné proměnné. [14]

2.3 Elektroencefalografické signály

Elektroencefalografie (EEG) je funkční pomocná diagnostická metoda, pomocí které jsou snímány s velkou časovou přesností elektrické potenciály vznikající během činnosti mozku. Záznam takovéto aktivity (tzv. elektroencefalogram) je souhrnem prostorové a časové sumace postsynaptických potenciálů, které jsou generovány neurony. Vstupní impulz v mozku excituje skupinu neuronů, kdy adekvátní odezvou na takovýto impulz je synchronizovaný elektrický výboj. Takto vygenerovaný výboj podráždí jiné skupiny neuronů v okolí, přičemž se postupně vytváří postupující vlna a zároveň dochází k útlumu předchozích excitujících neuronů do klidového stavu, dokud nedojde k opakování celého procesu. Celková velikost vlny potom odpovídá množství synchronizovaných neuronů produkující výboje. EEG tedy slouží k odhalení změn v elektrické aktivitě mozku. Snímá se signál vzniklý superpozicí celé řady jednodušších signálů.

Jednotlivé EEG rytmy můžeme odlišovat např. podle lokalizací na povrchu lebky, velikostí amplitudy, frekvenčního rozsahu nebo také vztahu k definovaným fyziologickým stavům, jako jsou spánek, bdění, volná pohybová aktivita, příjem a zpracování sensorické informace a změna vnitřního prostředí.

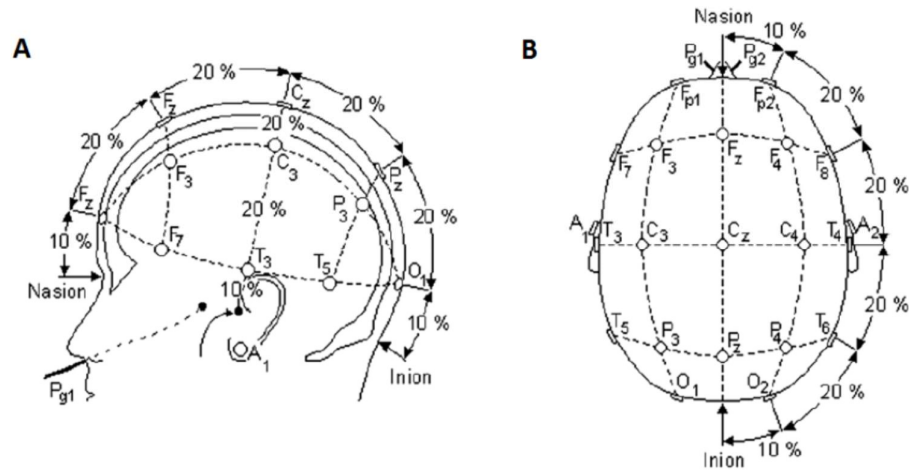
V EEG signálu se kromě základních EEG rytmů mohou vyskytovat další charakteristické a diagnosticky významné vlny označované jako tzv. grafoelementy, nápadně odlišné s negativní hlavní komponentou. Mezi takové se řadí např. epileptiformní hroty Wicked spikes, K-komplex (objevuje se těsně před spaním), dále SSS (BETS) vlny, při jejímž výskytu je téměř 100 % pravděpodobnost, že dotčený trpí epilepsií. Dále se mohou detekovat různé ostré vlny (Sharp waves), vlny vertexové, lambda vlny objevující se převážně v okcipitální oblasti (jejich vznik je přičítán upoutání zraku) atd. [8]

2.3.1 Snímání signálu EEG

Měření EEG signálů se zajišťuje pomocí přístroje zvaného elektroencefalograf. Elektroencefalograf. Ten pracuje na principu snímání elektrického potenciálu pomocí elektrod umístěných na povrchu hlavy. Elektrody snímají rozdíly elektrických potenciálů (kolem 10 mV).

Pro snímání EEG signálů jsou nejčastěji používané povrchové (skalповé) popřípadě podkožní elektrody. Skalповé elektrody jsou ploché a mají kruhový tvar o průměru 7–10 mm. Elektrody bývají stříbrné, tvořené vrstvou chloridu stříbrného Ag/AgCl. Z dalších materiálů se využívá zlato, nebo u speciálních elektrod nerezové oceli popř. speciální slitiny. Kov, z kterého je elektroda vyrobena je určující pro elektrickou charakteristiku elektrod. Pro měření se využívá tekuté médium mezi

povrchem elektrody a kůží pacienta. Elektroda a aplikace vodivého gelu vytvářejí v klidovém stavu elektrický potenciál. Při průchodu proudu nastává ovšem polarizace. Je zde tedy nutné využívat elektrody z takových kovů, které polarizaci odolávají a lze díky nim zaznamenávat rychlé změny elektrického potenciálu. [2]



Obr. 3 Rozmístění elektrod podle mezinárodního 10-20 systému. [13]

Elektroencefalografické záznamy jsou obvykle snímány větším počtem elektrod, zpravidla 19 až 64. V praxi se rozmístění elektrod na povrchu lebky řídí podle mezinárodní konvence, kdy je standardně využíváno tzv. systému 10-20 (viz obr. 3). Ten umožňuje pokrytí skalpu soustavou elektrod, přičemž obvod hlavy je rozdělen na úseky po 10 % a 20 %. Poloha jednotlivých elektrod je pak odvozena podle soustavy linií, vedených mezi kostěnými výstupky na hlavě. Podobným systematickým způsobem probíhá rozměření ve zbývajících dvou kolmých rovinách. Vzniká tím síť bodů, podle kterých jsou pak umísťovány elektrody na standardní místa. Tento mezinárodní systém zaručuje reprodukovatelnost vyšetření u téhož pacienta stejně jako u pacientů jiných. Zapojení je většinou realizováno pomocí speciální EEG čepice.

Zapojení měřícího aparátu při elektroencefalografickém měření je podobně jako u elektrokardiogramu řešeno s využitím dvou základních zapojení elektrod, unipolárního i bipolárního.

- **Bipolární režim** – zapojení je zde řešeno měřením rozdílů elektrických potenciálů mezi dvěma aktivními (explorativními) elektrodami.
- **Unipolární režim** – měření je zde prováděno za pomoci aktivní elektrody umístěné na hlavě a indiferentní (referenční) elektrody, která je nejčastěji připevněna na ušním lalůčku

2.4 EOG signály

Elektrické signály oka se snímají a zaznamenávají pomocí elektrookulogramu (EOG). Jedná se o záznam elektrického potenciálu měřeného mezi rohovkou a sítnicí oka. Těto signál je poté úměrný vertikálním a horizontálním pohybům oka. Velikost signálu dosahuje v rozmezí 0,01 -5,0 mV s frekvenčním rozsahem 0,05 – 100 Hz.

Rychlé pohyby oka se vyskytují během spánku především ve fázi REM při zavřených očích, naopak zpomalení nastává ve fázi N1. EOG signály hrají také důležitou roli v návaznosti na snímání a měření EEG aktivity, jelikož elektrická aktivita zapříčiněná pohyby oka nebo očí interferuje právě s EEG signály, což tedy způsobuje artefakty. Síla interferujícího EOG signálu závisí primárně na blízkosti elektrody vůči oku a směru, ve kterém se oko pohybuje. Artefakt z pohybu oka může být někdy chybně zaměněn s pomalou aktivitou EEG, např. v pásmu theta nebo delta. Další možné artefakty vznikají díky pohybu víček (mrknutí), které zasahuje do elektrického potenciálu mezi sítnicí a rohovkou. Dalším artefaktem, který je zasahuje do EEG signálu je artefakt vznikající díky blikajícímu světlu. Charakteristika tohoto signálu připomíná více čtvercovou vlnu a obsahuje více vysokofrekvenčních komponent. Z pohledu zpracování artefaktů v EEG signálech související s pohyby očí je velmi praktické a doporučeno měření EOG pomocí dvou referenčních elektrod umístěných v blízkosti oka. Dostupnost takovýchto referenčních signálů je užitečná, jelikož jsou korelovány s EOG v EEG signálech, a dají se využít pro následné vyrušení vzniklých artefaktů. [2]

2.5 EMG signály

Elektromyografie se zabývá elektrickou aktivitou kosterních svalů a podává informace o struktuře a funkci svalstva. Záznam, který je takto pořízen se nazývá elektromyogram (EMG). Během snímání EMG signálu se zaznamenává signál z velkého množství motorických jednotek, a amplituda signálu během měření je asi 10 mV. Frekvence se pohybuje zhruba do 500 Hz., v závislosti na tělesné stavbě jedince. Hlavní spektrální pásmo EMG svalů se nachází mezi 50–150 Hz. Snímací elektrody signálu EMG dělíme na povrchové, jehlové a drátové.

Z pohledu PSG signálů se snímání ENG signálů provádí zpravidla v oblasti brady a potom nohou. Snímání na bradě je zajištěno pomocí 3 elektrod. V této práci budeme využívat právě EMG snímaného z brady kvůli možnému rozlišení REM fáze, která by mohla být charakteristická jistým „neklidem“ svalů v okolí brady.

3 POSTUP AUTOMATICKÉ KLASIFIKACE SPÁNKOVÝCH FÁZÍ Z PACIENTSKÝCH DAT

Kromě odborného vyhodnocování zaznamenaného signálu se začíná mnohem frekventovaněji využívat výpočetních metod pro automatizované vyhodnocování. Většina metod pro automatickou detekci spánkových epoch je založena na segmentaci signálu, která je základem procedury pro získání klasifikačních příznaků a následných klasifikačních kroků. Jednotlivé procesní kroky vedoucí ke klasifikaci můžeme rozřadit do jednotlivých po sobě následujících sekvencí. Schéma procesu je znázorněno na obr. 4.

3.1 Segmentace

Segmentační metody představují rozdělení signálu na kratší úseky, přičemž se zpravidla vykonává z důvodu nalezení úseků s pokud možno neměnnými charakteristikami, nebo vykazující pouze malé rozdíly. Mezi základní typy segmentace patří segmentace:

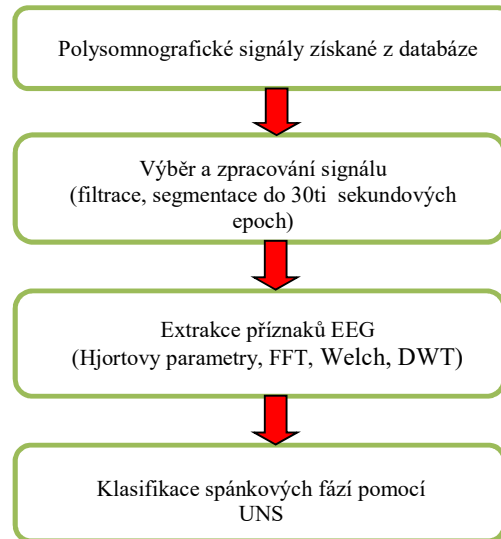
- konstantní
- adaptivní

Konstantní segmentace se využívá pro separování stejně dlouhých úseků se stejným počtem vzorků. Takový to druh segmentace se často využívá pro zpracování PSG signálů, kdy se zpravidla volí délka úseku 20–30 sekund. V rámci této práce bude využívat úseků o délce 30 sekund.

3.2 Výpočet příznaků

Kromě segmentace je potřeba nalézt vhodné parametry, které poté slouží pro samotnou klasifikaci, tento proces se nazývá extrakce příznaků. Dříve získané segmenty podle vhodně zvolené segmentační metody rozřazujeme do skupin tak, aby jednotlivé skupiny obsahovaly segmenty, které byly označeny na základě vizuálního hodnocení spánkového průběhu (hypnogramu). Pro nalezení příznaků můžeme použít výsledky ze statistického vyhodnocování (minimum, maximum, střední hodnota, rozptyl atd.). Často se také využívá hodnot výkonových spekter (absolutní, relativní), která získáme pomocí transformace signálů jako Fourierova transformace, popř. také pomocí statických hodnot z vlnkových koeficientů

získaných díky vlnkové transformaci. Dále se dají využít koeficienty korelace či koherence.



Obr. 4 Diagram navrhovaných metod vedoucích ke klasifikaci EEG signálu

3.2.1 Analýza EEG signálu

Existuje více možností jak ke zpracování a analýze EEG signálu přistupovat. Záleží na charakteru analýzy, zdali potřebujeme provést časovou analýzu průběhu EEG, frekvenční, nebo analýzu v časově frekvenční oblasti (Fourierova transformace, Waveletova transformace, Matching pursuits transformace, Hjortovy parametry) [6]. Pro automatickou analýzu změn mozkové aktivity je však vhodnější využití znalosti o frekvenčním složení signálu. U každé takovéto analýzy signálu je nutné brát v potaz povahu naměřených signálů a jejich vlastnosti, které každý signál charakterizují a tím také předurčují způsob a metodu analýzy.

3.2.2 Analýza v časové oblasti

Pro analýzu v časové oblasti se zejména využívají statistické parametry jako střední hodnota:

$$x_{stř} = \frac{1}{N} \sum_{i=1}^N x_i \quad (3.1)$$

Kde N udává počet vzorků x_i zkoumaného signálu x v epoše.

Dále míru rozptylu hodnot ve statistickém souboru:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - x_{stř})^2, \quad (3.2)$$

A také směrodatná odchylka:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - x_{stř})^2}, \quad (3.3)$$

Mezi další parametry, které se hojně využívají patří Hjorthovy deskriptory. Ty slouží pro analýzu signálu pomocí tří stěžejních parametrů, které byly původně navrženy pro online analýzu EEG.

Aktivita (nultý moment) – jedná se o rozptyl EEG signálu. Lze ji interpretovat také jako nultý moment ve frekvenční oblasti, kdy může být spjatý s jeho nultým momentem v oblasti časové, kdy celková energie ve frekvenční oblasti je rovna průměrné energii v oblasti časové. Aktivita je definována vztahem:

$$H_0 = M_0 = \int_{-\infty}^{\infty} S_{xx}(\omega) d(\omega) = 2\pi\sigma_x^2, \quad (3.4)$$

Mobilita – počítaná z úseku signálu je odhadem střední, tedy dominantní frekvence. Jedná se o střední odchylku sklonu, resp. o první derivaci signálu. Lze ji spočítat jako odmocninu rozptylu první derivace a zároveň vydělením rozptylem signálu:

$$H_1 = \sqrt{\frac{M_2}{M_0}} = \sqrt{\frac{\int_{-\infty}^{\infty} \omega^2 S_{xx}(\omega) d(\omega)}{\int_{-\infty}^{\infty} S_{xx}(\omega) d(\omega)}} = \frac{\sigma_{x'}}{\sigma_x} \quad [rad/s] \quad (3.5)$$

Komplexita (Složitost) – je odhadem šířky pásma signálu. Jedná se o poměr mobility první derivace a signálu a samotného signálu:

$$H_2 = \sqrt{\frac{M_4}{M_2} - \frac{M_2}{M_2}} = \sqrt{\left(\frac{\sigma_{x''}}{\sigma_{x'}}\right)^2 - \left(\frac{\sigma_{x'}}{\sigma_x}\right)^2} \quad [rad/s] \quad (3.6)$$

kde σ_i značí varianci (druhou mocninu standardní odchylky) i -té derivace signálu nebo střední hodnotu výkonu. Nultá derivace přitom koresponduje se samotným signálem.

$$H_2 = \frac{\sqrt{M_4/M_2}}{\sqrt{M_2/M_0}} = \frac{\sqrt{\sigma_2/\sigma_0}}{\sqrt{M_2/M_0}} = \frac{\sigma_2}{\sigma_0} \quad (3.7)$$

Všechny tři deskriptory jsou ekvivalencí nultému, druhému a čtvrtému spektrálnímu momentu (M_0 , M_2 a M_4) a můžou být vztaženy také k průměru výkonu v epoše, průměrnému výkonu normalizované derivaci a zároveň druhé derivaci v epoše. Hjorthovy parametry mohou být extrahovány pro použití jako vstupní příznak ke klasifikaci. [15][30]

3.2.3 Analýza ve frekvenční oblasti

Spektrální analýza slouží obecně k nalezení popisu signálu pomocí jeho složek ve spektrální oblasti. Pro popis vlastností spektra náhodných signálů se používají spektrální charakteristiky. Obecně platí, lze-li najít popis signálu ve frekvenční oblasti, tedy velikosti a případně i vzájemný fázový posun (časový) posun harmonických složek určitých kmitočtů, lze z toho usuzovat charakter signálů, tedy signál klasifikovat nebo rozpoznat [1].

U náhodných signálů se setkáváme s pojmem spektrální výkonová hustota (angl. PSD - power spectral density), která popisuje rozložení hustoty výkonu signálu v závislosti na frekvenci. [17].

Odhad spektrální výkonové hustoty můžeme rozdělit do dvou kategorií:

- Neparametrické, kde hodnoty PSD jsou odhadovány přímo ze signálu a slouží pro odhad spekter náhodných procesů.
- Parametrické, kde tyto metody jsou založeny na předpokladu, že signál je popsán pomocí parametrického modelu, čili soubory parametrů. Koeficienty tohoto modelu pak můžeme získat různými metodami.

Fourierova transformace

Pro neparametrické metody, které budeme v této práci výhradně využívat je typickým reprezentantem odhad výkonového spektra pomocí metod založených na Fourierově Transformaci. U této metody předpokládáme, že každý periodický signál

Lze reprezentovat součtem základních sinusovek a kosinusovek o příslušné amplitudě a frekvenci. Metody založené na Fourierově transformaci jsou pak velice snadno realizovatelné skrze výpočet rychlé Fourierové transformace (FFT – Fast Fourier Transformation), která rapidně zkracuje dobu výpočtu FT. [1]

Diskrétní Fourierova (angl. DFT, Discrete Fourier Transformation) transformace je definována vztahem:

$$DFT\{f_{w_i}(n)\} = \left\{ F_{w_i}(k) = \sum_{n=0}^{N-1} f_{w_i}(n)e^{-j(2\pi/N)kn} \right\} \quad (3.8)$$

PSD představuje pro náhodné signály vyhlazené výkonové spektrum jednotlivého signálu $f_{w_i}(n)$, kde $n=0, N-1$. Hodnoty k jsou poté jednotlivé koeficienty DFT. Výpočet PSD se pak v případě nestacionárních signálů stanoví odhadem, a děje se tak většinou na základě průměrování výkonových spekter přes počet M realizací náhodného signálu.

Periodogram

Periodogram patří mezi základní neparametrickou metodu výpočtu ve spektrální oblasti, díky níž lze určit výkon konkrétní harmonické složky signálu, jedná se zde tedy o odhadu výkonového spektra signálu $f_{w_i}(n)$. Výpočet periodogramu podle základního předpokladu však využívá pro odhad spektra pouze jedné realizace analyzovaného signálu. Takovýto odhad spektrální výkonové hustoty je označován jako vychýlený a nekonzistentní, a může vykazovat velký rozptyl, jenž neklesá s rostoucí délkou signálu.

Přesnějšího odhadu můžeme dosáhnout průměrováním periodogramu přes M realizací signálu, a to podle vztahu:

$$S_{ff}(\omega) = \frac{1}{M} \sum_{w_i=w_1}^{w_M} \frac{1}{N} |F_{w_i}(\omega)|^2, \quad (3.9)$$

Jedná se v principu o souborový průměr individuálních výkonových spekter z M realizací o délce N vzorků signálu $f_{w_i}(n)$. V praxi ovšem známe pouze jednu realizaci, v tom případě lze analyzovaný signál rozdělit na již K kratších úseků, z čehož pak vychází další modifikace výpočtu periodogramu. Zmenšení rozptylu je pak přímo úměrné počtu segmentů. [1]

Welchova metoda

Další možnou metodou, jak redukovat rozptyl spektrální výkonové hustoty získané z periodogramu je tzv. Welchova metoda, která je kromě průměrování navíc ještě modifikována. Signál je rozdělen prvně na segmenty, kdy jednotlivé segmenty se navzájem překrývají, přičemž nejčastěji je zvoleno překrytí 50 %, nebo 75 %. Každý segment je násoben vhodným váhovacím oknem $w(n)$, čímž se dosáhne nižšímu prosakování do vzdálenějších kmitočtů [1]. Z takto váhovaných segmentů se vypočítá spektrální hustota:

$$F_{w_{i\text{modif}}}(\omega) = DFT\{f_{w_i}(n)\} = \frac{1}{UN} \sum_{n=0}^{N-1} f_{w_i}(n)w(n)e^{-j(2\pi/N)kn} \quad (3.10)$$


přičemž N je celková délka, z které je počítáno DFT. Koeficient U je tzv. normalizační koeficient (norma vektoru okénkové funkce) a je dán vztahem:

$$U = \frac{1}{N} \sum_{n=0}^{N-1} w^2(n) \quad (3.11)$$

Welchův odhad výkonové spektrální hustoty je definován jako průměr L dílčích modifikovaných periodogramů:


$$S_{ff\text{welch}}(\omega) = \frac{1}{L} \sum_{w_i=w_1}^{w_M} |F_{w_{i\text{modif}}}(\omega)|^2 \quad (3.12)$$

Výsledný odhad výkonové spektrální hustoty pak závisí na všech jednotlivých parametrech, tedy délce úseků, velikosti překrytí sousedních oken, a typu váhovacího okna. Výsledný průběh spektra je pak díky této metodě hladší, a s odhadem se lépe pracuje. Metoda tedy slouží pro konzistentní odhad výkonové spektrální hustoty. [1]



Obr. 5 Grafické znázornění získání periodogramu Welchovou metodou převzato z [27]

Na obr. 5 je znázorněn postup výpočtu, kdy je signál rozdělen na L segmentů, každý o zvolené délce K vzorků. Jednotlivé segmenty jsou umístěny buď těsně vedle sebe, tedy celkový signál délky $N = K \times L$, nebo se mohou vzájemně překrývat. Každý segment vstupního signálu je následně váhováno vhodným oknem typu např. *Hamming*.




Obr. 6 Ukázka výkonové spektrální hustoty získané pomocí Welchova modifikovaného periodogramu.

3.3 Časově-frekvenční analýza signálů

Při analýze signálů, jejichž charakter se v čase rychle mění, (signály s nestacionární povahou), čili signálů přechodového charakteru je dobré postavit úvahy směřující ke zpracování na frekvenčním obsahu krátkých signálových úseků. Tím se dostáváme ke konceptu tzv. krátkodobých spekter. Tento koncept je v praxi velice jasně aplikovatelný, jelikož analýza vychází zpravidla čistě jen z konečných úseků signálů tzv. krátkodobých segmentů, vymezených použitým typem okna. Pokud má okno nastavenou vhodnou délku N a je definováno jako klouzavé na

časové ose, lze tento přístup použít také pro časově-frekvenční analýzu. Pozorovací interval je u takového typu analýzy kompromisem mezi požadavkem na dostatečnou rozlišovací schopnost ve frekvenční oblasti (rozlišitelná diference frekvencí je nepřímo úměrná délce okna), a zároveň také snahou o zřetelné rozlišení v čase (minimální rozlišitelný časový rozdíl je úměrný délce okna. Takovýto přístup umožňuje formulovat obecněji spektrum jako dvojrozměrnou funkci, která je závislá jednak na frekvenci, tak také na pozici v čase. [1]



Obr. 7 Spektrogramy získané z krátkodobých spekter signálu EEG pro fázi W a N3, a) pro fázi wake jsou vidět vysoké hodnoty krátkodobých která pokrývají širší rozpětí frekvencí (červená oblast), b) u spánkové fáze N3 lze vidět, že červená oblast zasahuje jen nižší kmitočty oproti fázi wake

K získání informace o časovém vývoji spektrálního složení signálu aplikujeme krátkodobá výkonová spektra. Jedná se o jednu ze základních charakteristik ve spektrální oblasti. Ze souboru takto získaných spekter pak dostáváme tzv. spektrogram, který může vyobrazěn jako dvojrozměrný obraz s osami, kdy jedna osa odpovídá frekvenci a druhá osa následně času (viz obr. 7). Barva popřípadě stupeň šedi, tedy úroveň jasů odpovídá amplitudě spektrálních koeficientů. [1]

3.4 Spektrální entropie

Pro případ EEG signálu určuje entropie míru složitosti, resp. Komplexnosti EEG signálu. Obecně s klesající entropií roste celková informace. Mezi parametry, které lze využít v oblasti entropie patří spektrální entropie. Ta je získávána jako entropie z odhadu výkonové spektrální hustoty P_f ze zkoumaného segmentu x . N_f je počet

spektrálních čar v odhadu spektra [17]. Dochází zde k normalizaci pro dané frekvenční pásmo. Je dána vztahem:

$$H_N = \frac{-1}{\log N_f} \sum_f P_f(x) \log_e(p_f(x)) \quad (3.13)$$

4 KLASIFIKAČNÍ MODELY

4.1 Popis a metody klasifikace

Pojem klasifikace zpravidla značí matematickou metodu, při níž vstupní objekty rozřazujeme do tříd podle podobných vlastností, které jsou vyjádřeny danými parametry. Třídy bývají tvořeny shluky. Klasifikovat data je možné s použitím základních metod:

Metoda klasifikace bez učitele

Podoba a často ani počet tříd není znám. Patří sem Shluková analýza, SOM (Samoorganizující se mapy), Kohonenovy mapy atd.

Metoda klasifikace s učitelem

U tohoto typu klasifikátoru je využívána tzv. trénovací množina (posloupnost jednotlivých dvojic vstupů a výstupů sítě). Známými prvky klasifikace je zde počet tříd, do kterých se má klasifikovat. Jedná se o adaptivní způsob, kdy požadované chování sítě modeluje učitel, který pro vzorové vstupy informuje adaptivní mechanismus o správném výstupu sítě. Mezi hojně vyžívané klasifikátory patří v této skupině klasifikátory K-NN klasifikátor, neuronové sítě, rozhodovací stromy atd. [23] [29]

4.2 K-NN (K-nejbližších sousedů)

K-NN (K-nejbližších sousedů) klasifikátor je možné zařadit mezi tzv. „pseudo“-učící se klasifikátory pro hledání a řazení do určených tříd. U tohoto klasifikátoru je nutná znalost a specifikace trénovací množiny, na které se klasifikátor naučí rozpoznávat příchozí objekty klasifikace, ovšem nedochází u něho k učení ve smyslu optimalizace parametrů modelu. Na druhou stranu objekt, který nebyl součástí množiny během trénování, bude mít problém se zařazením. [17]

Základním problémem je zde neurčitá hranice mezi jednotlivými třídami, jelikož vzorky náležící jednotlivým klasifikačním třídám se mohou navzájem překrývat. U této metody poté probíhá rozhodování, ke které třídě vzorek náleží pomocí předem dané metriky výpočtu vzdálenosti k stanovenému počtu nejbližších sousedů. Zpravidla nejčastěji používaná je tzv. Euklidovská vzdálenost

$$d_E(x, y) = \|x - y\| = \sum_{i=1}^n (x_i - y_i)^2 \quad (4.1)$$

nebo např. Minkowského metrika dána vztahem:

$$D_M(x, y) = \left(\sum_{i=1}^n |x_i - y_i| \right)^{\frac{1}{\lambda}}, \lambda \in \mathfrak{R} \quad (4.2)$$

Nebo také Hammingova metrika, která hledá rozdíly mezi jednotlivými elementy, celková vzdálenost je poté součet absolutních hodnot získaných rozdílů:

$$H(x, y) = \sum_{i=1}^N |x_i - y_i| \quad (4.3)$$

Kde vzdálenosti mezi všemi vzorky x_i příslušející do stejné třídy X_j , jsou optimálně co nejmenší a naopak rozdíly ve vzdálenostech mezi jednotlivými třídami jsou poté rozdíly největší. Objekt je potom zařazen do stejné třídy, kam je přiřazena většina objektů z jeho okolí. Toto okolí se zpravidla definuje za pomoci parametru k . U této metody tedy výsledek klasifikace závislý na počtu definovaných sousedů a na zvoleném metrice určující rozhodování.

4.3 SVM (metoda podpůrných vektorů)

SVM (angl. *Support Vector Machine*) klasifikátory nebo také algoritmy podpůrných vektorů, se řadí mezi prostředky zpracování analýzy vícerozměrných datových souborů. Jedná se o tzv. jádrové klasifikátory, které jsou tvořené algoritmickým jádrem. Typ jádra se zpravidla volí podle složitosti, a oddělitelnosti dat, kdy obsahuje určitý algoritmus, který se nejlépe hodí pro zpracování dané úlohy. Cílem metody je opět nalezení optimální hranice mezi skupinami příznaků v tzv. příznakovém prostoru, které jsou podrobovány klasifikaci. Tyto prostory můžou mít

podobu vícedimenzionálních prostorů. Hledá se zde optimální nadrovina, která dokáže maximalizovat rozestupy mezi skupina. Tato nadrovina je potom dána hodnotami podpůrných vektorů, které představují body ležící na okraji pásma, tvořícího nadrovinou. Neplatí zde ovšem omezení pouze na lineární data, algoritmus lze uplatnit i na data nelineárně oddělitelná. Jádrové algoritmy lze rozdělit na:

- Lineární algoritmy
- Nelineární algoritmy – do skupiny těchto jádrových funkcí patří například algoritmy RBF (angl. Radial Basis Function), polynomy vyšších řádů.

4.4 Neuronové sítě

Umělé neuronové sítě (UNS) lze definovat jako struktury skládající se složitě propojených procesních jednotek (neuronů), které jsou schopny vykonávat náročné paralelní výpočty pro zpracování dat a určování analýz na základě znalostí.

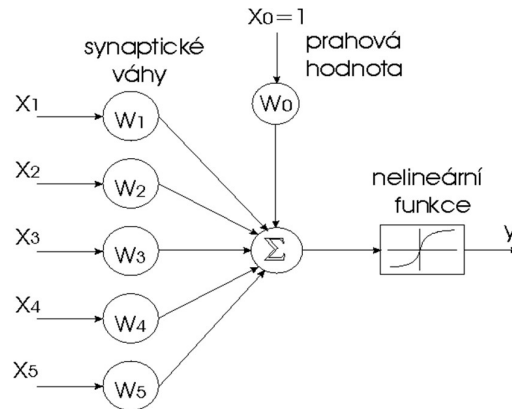
UNS jsou velice vhodné pro zobecňování dat a způsobilé pro řešení nelineárních problémů. Dokáží také extrahovat a reprezentovat vnitřní závislosti v datech a vyznačují se schopností klasifikace, regrese a predikce. Mohou nabízet potencionálně vyšší metody pro analýzu EEG signálů k metodám spektrální analýzy. Pomocí UNS lze určovat do jaké třídy signál náleží.

Jako vstupy pro umělé neuronové sítě lze s úspěchem použít extrahované hodnoty získané např. ze spektrální analýzy pomocí FFT nebo diskretní vlnkové transformace (DWT). Ty se poté přiřadí na vstup vícevrstvé neuronové sítě. Díky takto navržené UNS pak může získat jednotlivá rozřazení podle skupin námi zkoumaných spánkových stádií (NREM, REM, bdělost atd.).

4.4.1 Popis funkce

Umělé neuronové sítě vycházejí z podobnosti s biologickým nervovým systémem. Základní stavební prvky nervové soustavy a především mozku tvoří neurony. Jsou to živé buňky, které slouží k sběru, uchování, zpracování a přenosu informací. Každý neuron se skládá z těla (soma), do kterého přicházejí informace po vstupních drahách (dendrity), a z kterého informace vystupují na jediném výstupu (axon). Výstupní signály axonů odpovídají vstupům dalších neuronů. Jednotlivé neurony jsou spolu navzájem propojeny do neuronových sítí, a to právě přes axony, které se pomocí speciálních výběžků (synapsí) připojují na dendrity jiných neuronů. Na jeden neuron připadá od desítky po několik tisíc spojů s jinými neurony. Přenos

signálu je zprostředkován elektrickými pulsy, které však aktivují neuron až po překročení určité hodnoty elektrického potenciálu (prahu). [8]




Obr. 8 Ukázka a popis umělého neuronu [26]

Základním prvkem umělých neuronových sítí je formální perceptron (obr. 8). Skládá se z těla, dendritů přenášející signál směrem k tělu a axonu přenášející signál od těla neuronu. Každá umělá neuronová síť obsahuje několik vrstev formálních neuronů. Napojení na dendrity jiného neuronu tvoří informační rozhraní a nazývá se synapse. Přicházející signál je v synapsi zvětšen nebo zmenšen popřípadě znegován vynásobením vahami. Výsledek vynásobení je dendritem veden do těla neuronu, kde se signály z jednotlivých dendritů sečtou. Vzniklý signál, který lze považovat za celkové podráždění neuronu (aktivaci neuronu) je porovnáván s prahem a přeskočí-li jeho hodnotu, dochází k sumaci dle rovnice:

$$a_i = \sum_{x=0}^N w_{i,j} y_{j,i-1} + b_i \quad (4.4)$$

Kde w_{i-1} je signál z neuronu v předcházející vrstvě, $w_{i,j}$ a b_i jsou váhy a prahy i -té vrstvy neuronové sítě. Hodnota a je pak transformována přenosovou funkcí na výstupní signál neuronu (y_i), který je axonem přenášen do jiného neuronu popř. přímo představuje požadovanou výstupní veličinu. Přenosová funkce označovaná také jako aktivační, převádí hodnoty sumací do definovaného oboru výstupních hodnot.



Obr. 9: Ukázka přenosové funkce a) logaritmická sigmoida b) tangens sinoida c) jednotkový skok d) lineární funkce (převzato z [20])

Nejběžnější používanou přenosovou funkcí je sigmoida (obr. 9), která vymezuje signálu hodnoty z otevřeného intervalu $(0, 1)$.

U signálu EEG lze jako vstupy pro umělé neuronové sítě s úspěchem použít extrahované hodnoty získané např. ze spektrální analýzy pomocí FFT nebo diskrétní vlnkové transformace (DWT). Tyto hodnoty alias příznaky se poté přiřadí na vstup vícevrstvé neuronové sítě. Díky takto navržené UNS pak může získat jednotlivá rozřazení podle skupin námi zkoumaných spánkových stádií (NREM, REM, bdělost atd.).

4.4.2 Vícevrstvé neuronové sítě

Vícevrstvé neuronové sítě se skládají minimálně ze tří vrstev, jedné vstupní (větvičí), která pouze distribuuje vstupní hodnoty do další vrstvy minimálně jedné skryté a jedné výstupní vrstvy zpravidla s dopředným propojením a šířením signálu (feedforward viz. níže). Znamená to, že neexistují propojení mezi neurony ve stejné vrstvě, ale pouze mezi vrstvami. Neurony v sousedních vrstvách jsou úplně propojené (obr.10) . U více vrstevných sítí se téměř standardně používají pro skryté vrstvy aktivační funkce typu sigmoida označované také jako *squashing* („mačkající“). Tyto funkce stlačují resp. převádějí nekonečnou oblast vstupů do konečné oblasti výstupů. Pro libolně velký vstup se potom strmost této funkce blíží nule, a v případě gradientu s velmi malými hodnotami se nastavení vah a prahů může rapidně lišit od optimálních hodnot. Tento problém lze korigovat pomocí tzv. Pružného učení (viz. dále). [23]

Vícevrstvé uspořádání neuronů s nelineárními přenosovými funkcemi dovolují síti učit nelineární i lineární vztahy. Lineární výstupní hodnoty se pohybují v rozmezí -1 až 1 , kdežto nelineární výstupy nabývají v případě aktivační funkce typu sigmoida hodnot mezi 0 a 1 .

Existuje věta, která hovoří, že na vyřešení libovolného problému stačí síť s dvěma skrytými vrstvami – v praxi se ale často používá vrstev méně. Obecně se doporučuje používat sítě s menším počtem vrstev, jelikož se rychleji učí. Naopak sítě s více vrstvami umí mnohem lépe zobecňovat.

4.4.3 Architektura neuronových sítí – topologie


Struktura každé neuronové sítě je dána způsobem propojení jednotlivých neuronů případně dalších hierarchicky vyšších neuronových skupin. Např. skupina navzájem propojených neuronů může být s dalšími neuronovými skupinami spojena pouze slabě či nepřímo, nebo naopak, všechny neurony dané sítě mohou být kompletně navzájem propojeny. Vazby mohou být pouze jednosměrné nebo na orientaci jednotlivých nemusí být kladen zvláštní důraz. [1] [23]

V architektuře neuronových sítí sledujeme, jaký typ propojení síť tvoří (úplné, nebo částečné). Dalším důležitým parametrem je počet vrstev a vazby mezi nimi

- dopředné šíření (feedforward), popř. zpětné šíření, bez zpětné vazby – stabilní, nejčastěji používané
- zpětnovazební (rekurzvní) síť – charakteristické problémy se stabilitou

Dopředné síť – feedforward

Klasická dopředná neuronová síť se skládá ze vstupní, skryté a výstupní vrstvy. Učební algoritmus této topologie je koncipován tak, že se výpočet šíří postupně ze vstupní k výstupní vrstvě. Následná chyba se potom šíří k prvotním vrstvám. Neurony skryté vrstvy jsou zpravidla aktivována funkcí typu sigmoida.



Obr. 10 Architektura dopředné neuronové sítě [26]

Způsob učení


- Učení s učitelem
- Učení bez učitele (samoorganizující sítě)

Trénování sítě

Trénování neuronové sítě patří do tzv. adaptační fáze, při které dochází k optimalizaci jejich parametrů. Zpravidla se zvolí algoritmus učení, což je postup, jakým se nastavují váhy v jednotlivých spojeních. Trénování takovéto sítě potom probíhá pomocí trénovací sady, kterou přivedeme na vstup a dále pak známé sady výstupů. Samotné trénování probíhá ve třech etapách. V první je aplikována trénovací množina, kterou použijeme k natrénování sítě. Druhá fáze je tzv. verifikační, přičemž verifikační etapa slouží k tomu, abychom znali dobu, po kterou bude trvat trénování sítě. Ve třetí fázi dochází k testování sítě pomocí tzv. testovací množiny, kterou použijeme pro vyhodnocení úspěšnosti natrénování sítě.


Rozeznáváme několik klasifikačních metod:

- **Metoda klasifikace bez učitele:** podoba a často ani počet tříd není znám. Je zde absence výstupu a cílem je vždy nastavení (adaptace) synaptických vah. Váhy se nastavují tak, aby byl výstup sítě konzistentní, tedy aby síť poskytovala stejnou odezvu při stejných, resp. podobných vstupních vektorech. Patří sem Shluková analýza, SOM (Samoorganizující se mapy), Kohonenovy mapy atd. Schéma znázorňující klasifikaci bez učitele je vidět na obr. 11.



Obr. 11 Schéma učení neuronu pomocí metody bez učitele

- **Metoda klasifikace s učitelem:** u tohoto typu klasifikátoru je využívána tzv. trénovací množina (množina objektů jednotlivých klasifikačních tříd). Mezi tyto klasifikátory patří k-NN klasifikátor, neuronové sítě, rozhodovací stromy atd. Grafické znázornění metody klasifikační metody učení s učitelem je znázorněno na obr. 12.



Obr. 12 Schéma učení neuronu pomocí metody s učitelem

Učení neuronové sítě s učitelem

Adekvátní fungování neuronové sítě závisí na velikosti trénovací množiny a zároveň také množiny testovací. Během trénování jsou vstupní data a data očekávaná na výstupu opakovaně předkládána síti. Pro trénování je tedy důležité zvážit rozdělení dat mezi trénovací set, a set určený pro testování. Zpravidla se toto rozdělení volí v poměru 80 % trénovací set a 20 % (zbytek) na testování. K získání lepší organizace sítě lze využít také tzv. cross-validace. Jako kritérium pro zastavení trénování sítě bývá stanovena cílová hodnota chybové funkce, zpravidla se jedná o střední kvadratickou chybu. Na vstup UNS vložíme zadaný známý vzor, přičemž na výstupu dostaneme výsledek, který odpovídá aktuálnímu nastavení váhových koeficientů.

Pro učení neuronové sítě lze využít algoritmy gradientní:

- Back-propagation
- QuickProp
- Quasi-Newton
- Levenberg-Marquardt
- Delta-bar-Delta

Popřípadě také algoritmy negradiční: evoluční techniky (GNARL, SANE, NEAT).

Vybavování a učení sítě

během vybavování vložíme na vstupy vzor a ten se postupně šíří dopřednou metodou přes váhy neuronů v jednotlivých vrstvách a s využitím aktivačních funkcí perceptorů až k výstupům sítě. Postupně se počítají hodnoty potenciálů od první k poslední vrstvě.

Algoritmus zpětného šíření chyby

Jedná se o nepoužívanější a nejznámější učící algoritmus, přičemž jde o typ zpětného šíření pro výpočet sumy čtverců chyb. Trénovací algoritmus back propagation je řízený učební algoritmus pro vícevrstvé dopředné neuronové sítě. Jelikož se jedná o

řízený učební algoritmus, oba vstupy a konečné výstupní vektory jsou poskytnuty pro trénování sítě. Chybové data a výstupní vrstva jsou vypočítány s využitím výstupu sítě a cílového výstupu. Chyba je posléze zpětně šíří na vnitřní vrstvy, které umožňují upravovat příchozí váhy těchto vrstev. V základu proces zpětného šíření chyby se skládá z dvou průchodů skrze rozličné vrstvy sítě, dopředný průchod a zpětný průchod. Během fáze dopředného průchodu je vstupní vektor aplikován do sítě a šířen vrstvou po vrstvě skrze síť. Nastavení výstupu je poté výsledkem aktuální odezvy sítě. Během tohoto procesu zůstávají synaptické váhy nezměněny. Algoritmus poté upraví jednotlivé váhy směrem od výstupních vrstev až ke vstupním. Tento cyklus se opakuje tak dlouho, doku není splněno zvolené kritérium, kterým může být například minimální suma čtverců reziduálních odchylek nebo počet cyklů. [23]

Sítě typu back-propagation jsou i přesto přes svou popularnost hůře uplatnitelné pro mnohé aplikace.

Učení probíhá ve třech etapách:

1. Síti je předloženo zadání.
2. Inicializují se váhy sítě s malými náhodnými čísly
3. Pro každý vzorek z trénovacích dat na vstupu se spočítá výstupní hodnota touto pro každý neuron v síti
4. po výstupu informací ze sítě se zjistí chyba oproti očekávanému výstupu

Základní algoritmy učení se zpětným šířením chyby

Zde je základním prvkem potenciál neuronu, kde výstup neuronu y je porovnáván s požadovanou hodnotou a jejich rozdíl $e = t - y$. Potenciál je potom dán

$$u = \sum_{i=0}^n w_i x_i = Wx \quad (4.5)$$

W zde značí matici vah a x je vstupní vektor. Trénování sítě spočívá v přivedení K vzorů na vstup matice a výpočtem odpovídajících výstupů y .

Výpočet sumy čtverců chyb je dán vztahem:

$$E = \sum_{k=1}^K [e(k)]^2 = \sum_{k=1}^K [t(k) - y(k)]^2 = \sum_{k=1}^K [t(k) - f(Wx(k))]^2 \quad (4.6)$$

Hlavním principem je úprava matice vah W a následně pomocí upravených hodnot vah mohlo být dosažena minimální chyba E . Jedná se o úpravu pomocí metody nejmenších čtverců.

Modifikované algoritmy učení se zpětným šířením chyby

U těchto metod se využívá vhodná volba rychlosti učení α , která by měla zamezit tzv. přeskočení lokálních minim nebo k následným oscilacím. Pracuje se zde s modifikacemi základních algoritmů, přičemž bývá využíváno adaptivní rychlosti učení, nebo momentu učení. Rychlost učení se zde určuje experimentálně, a zjišťuje se maximální možná změna rychlosti učení pro stabilní učení. Tyto přídatné parametry vedou k rychlejší konvergenci a snížení pravděpodobnosti uvíznutí v lokálním minimu. Modifikované algoritmy lze rozdělit na:

- **Heuristické optimalizační metody** – gradientní učení s momentem, snižuje citlivost učení na detaily chybové funkce, dovoluje síti odpovídat na lokální gradient. Jeho chování je typu dolní propust tedy dovoluje malé změny obálky chybové funkce. Tento způsob je zpravidla rychlejší než základní. Ostatní modifikace poté patří mezi tzv. učení s proměnnou rychlostí. Oproti momentovému učení konvergují většinou 10-krát až 100-krát rychleji. Dále do této skupiny spadají také algoritmy tzv. pružného učení angl. Resilient Back Propagation (RSBP) a algoritmy adaptivního učení angl. Variable Learnig Rate.
- **Deterministické optimalizační metody** – tyto metody využívají standardní numerické optimalizační metody např. metodu konjugovaného gradientu, kvazi-Newtonovu (QNBP) metodu a Levenberg-Marquardtův algoritmus (LMBP). [23]

Výběr vhodné a zároveň také rychlé modifikace BFG algoritmu k odpovídající úloze nebo aplikaci bývá zpravidla komplikované. Vhodnost závisí na mnoha faktorech jako je typ úlohy, nastavená dovolená chyba, komplexnosti úlohy, na počtu a charakteru dat v trénovací množině atd. Obecně lze říct, že pro Levenberg-Marquardtův algoritmus, který je považován za nejrychlejší na úkor paměťové náročnosti, je výhodné použití u malých sítí, a nevhodný u úloh rozpoznávání, kde se lépe uplatní síť s pružným učení. Konjugované gradientní metody se více uplatní u sítí s velkým počtem vah. [23]

5 ANALÝZA POLYSOMNOGRAFICKÝCH SIGNÁLŮ

5.1 Popis dat

Pro zkoumání a hodnocení spánkových fází byly využity signály, které byly získány z databáze FNUSA. Ty obsahují kompletní polysomnografické naměřené signály, které byly již dříve podrobeny lékařskému ohodnocení spánkových fází podle standardů AASM k rozlišení jednotlivých fází. V rámci této práce byly využívány vybrané polysomnografické signály EEG a EOG. Jednotlivé signály byly snímány pomocí párových elektrod, o vzorkovací frekvenci 256 Hz. V našem případě byl vybrán signál z elektrod Cz-Oz a E2. Tabulka 2 obsahuje anonymní pořadový výčet osob, jejichž signály byly v práci zpracovávány. Signály byly prvně pomocí převodníku "EDFtoASCII" přichystány do "ASCII" formátu a poté pomocí matlabovského souboru "EEG_phys_nacteni" převedeny do požadovaného formátu ".mat". Signály byly poté segmentovány po úsecích délky 30 sekund při vzorkovací frekvenci $f_{vz} = 256$ Hz tedy jeden úsek tvořilo 7680 vzorků. Takto bylo dosaženo toho, aby segmenty odpovídaly předchozímu lékařskému ohodnocení. Jednotlivé segmenty pro skupinu danou typem spánkové fáze byly uloženy do matice a poté zpracovávány společně s dalšími vybranými signály v rámci extrakce příznaků, jejich statistického vyhodnocení a následnou klasifikaci.

Box grafy (krabicové grafy)

Rozložení číselné veličiny lze dobře vizuálně vyobrazit pomocí tzv. box grafu (krabicového grafu nebo diagramu). Ten je tvořen obdélníkem, který je rozdělen vodorovnou čarou na dvě části, a dvěma svislými čarami. Tyto svislé čáry vedou z dolní a horní hrany obdélníku. Rozdělovací vodorovná čára představuje tzv. medián (eventuálně průměr), a tvoří střed rozložení sledované veličiny, tedy polovina všech pozorování leží pod vodorovnou čarou, a druhá polovina na čarou. Horní a dolní okraje obdélníku tvoří tzv. kvartily (horní a dolní kvartil). Horní kvartil poté rozděluje horní polovinu dat na další dvě poloviční části. Nad ní leží hodnoty, patřící do jedné čtvrtiny nejvyšších hodnot. Dolní kvartil jakožto spodní okraj obdélníku odděluje dolní čtvrtinu hodnot. Vnitřní množina hodnot obdélníku představuje polovinu všech pozorování. Svislé čáry, vedoucí z hran obdélníku (tzv. fousky) směřují poté k nejvyšší, resp. nejnižší hodnotě pozorování. [31]

Anova – analýza rozptylu

Pro srovnání dvou a více výběrů lze zvolit např. test ANOVA, která se řadí mezi tzv. neparametrické testy. U tohoto testu je důležité dodržení předpokladů ke správnosti testu: nezávislost výběrů, normalita rozdělení, identické rozptyly. K testu normality lze použít např. Shapiro-Wilkův test, Kolmogorov-Smirnovův test nebo Lillieforsův test. V našem případě byl použit Kolmogorov-Smirnovův test, který je dostupný jako funkce Matlabu. Během testování pomocí Kolmogorov-Smirnovův testu bylo zjištěno, že jsou splněny požadavky na možnost testování pomocí analýzy rozptylu.

ANOVA porovnává rozptyl mezi skupinami a rozptyl ve skupinách, pokud je poměr rozptylu uvnitř skupin k rozptylu mezi skupinami signifikantně vyšší, ANOVA test vyhodnotí závěr, že střední hodnoty obou skupin jsou od sebe signifikantně rozdílné. To je možné změřit použitím statistiky, která má F -rozdělení s $k-1, N-1$ stupňů volnosti. [31]

Při testování hypotézy o středních hodnotách lze tedy využít výstupů testů jako je hodnota testovaného kritéria t , počet stupňů volnosti df , p -hodnota, interval spolehlivosti a odhad středních hodnot. Zpravidla testujeme, jestli soubor hodnot, který chceme klasifikovat je prokazatelně signifikantní na určené hladině významnosti, a tedy rozdílný oproti jinému souboru. Hladina významnosti se zpravidla volí 0,05, tedy testujeme, jestli hodnota p je $p < 0,05$. Pomocí testu ANOVA bylo zjištěno, jestli jsou mezi všemi skupinami nějaké signifikantní rozdíly. Dalším postupem byly nalezeny statisticky významné rozdíly mezi již konkrétními skupinami tak, aby se dalo brát během výběru vhodných příznaků v úvahu, které skupiny budou pravděpodobně dobře klasifikovatelné a které hůře. Za tímto účelem slouží tzv. Post-hoc analýza, která v sobě zahrnuje párové porovnání jednotlivých skupin. K realizaci tohoto porovnání lze použít funkci Matlabu *multcompare*, která využívá metodu HSD Tukey, a vrací přehledovou tabulku získaných hodnot porovnání. [31]

V první etapě chceme uskutečnit klasifikaci do dvou skupin, a to spánku (S) a fázi bdění (W). Hodnoty pro fázi spánku dostaneme sečtením hodnot všech epoch (REM, N1, N2 a N3), které byly rozčleněny během zpracování parametrů signálu. Tedy mediánové hodnoty krabicových diagramů by pro tyto fáze neměly být na stejné hladině, a jejich kvantily by se neměly, pokud možno překrývat.

5.2 Výpočet příznaků z průběhu EEG, EOG, EMG

Ze získaných třiceti sekundových segmentů byly extrahovány jednotlivé příznaky pro časovou a frekvenční oblast. Pro další práci pak byly příznaky rozděleny do skupiny podle spánkových fází. K rozdělení příznaků bylo využito manuálního lékařského skórování pro daný signál získaný jako balík souborů polysomnografického měření z databáze FNUSA (Fakultní nemocnice u svaté Anny v Brně).

Tabulka 2 Počet epoch v jednotlivých spánkových fázích získané ze signálu pro zpracování EEG

	Snímaná osoba	Spánková fáze				
		W	REM	N1	N2	N3
1.	Signál_002	20	18	22	624	79
2.	Signál_012	23	114	9	537	187
3.	Signál_015	333	44	139	189	81
4.	Signál_016	120	92	121	331	162
5.	Signál_018	237	62	44	474	43
6.	Signál_019	256	135	72	308	81
7.	Signál_024	98	56	15	595	188
8.	Signál_030	173	36	185	549	43
9.	Signál_032	101	105	68	360	191
10.	Signál_033	248	61	152	195	70
11.	Signál_034	361	59	91	376	31
12.	Signál_035	152	61	154	456	67
13.	Signál_038	95	122	110	298	74
14.	Signál_040	56	188	67	275	133
15.	Signál_041	197	112	243	267	91
16.	Signál_042	248	27	105	413	90
17.	Signál_043	290	44	42	317	117
18.	Signál_046	106	177	163	226	110
19.	Signál_047	129	154	97	82	259
20.	Signál_048	76	77	215	137	139
21.	Signál_049	331	98	150	102	139
22.	Signál_050	414	40	386	105	103
23.	Signál_052	329	34	75	249	132
24.	Signál_053	218	205	225	64	108
	celkem	4611	2121	2950	7529	2718

K dalšímu zpracování byly použity signály od 24 pacientů. (Tabulka 2). Pro výpočet parametrů EEG signálu byly použity jednotlivé epochy tvořící segmenty, které byly z důvodu lepší systematičnosti rozděleny dle lékařského ohodnocení podle jednotlivých skupin na skupiny bdělost (Wake), REM, N1, N2 a N3. Ze vzniklých skupin segmentů byly dalším zpracováním vyextrahovány tzv. příznaky, jako parametry či charakteristiky popisující chování signálů v určitých spánkových fázích jednak v časové oblasti, ale také ve frekvenční oblasti. Na základě těchto skupin bylo možné tyto fáze klasifikovat z jiného úhlu pohledu, než jen čistě z pohledu lékařského.

5.2.1 Příznaky v časové oblasti

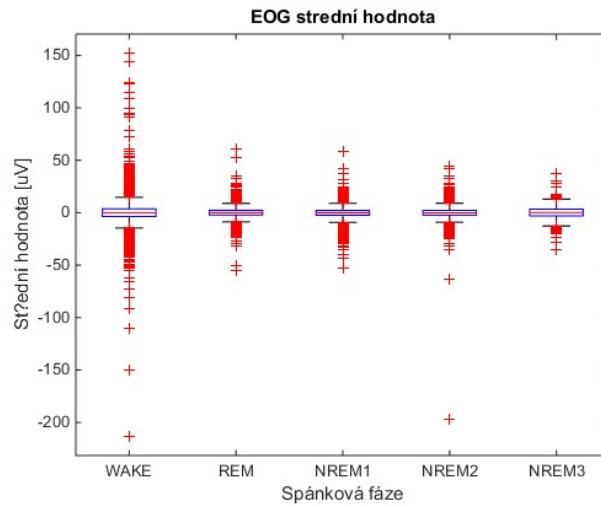
Pro analýzu příznaků PSG signálů byly v časové oblasti vybrány statistické parametry typu střední hodnota, standardní odchylka, a dále parametry patřící do skupiny tzv. Hjorthových deskriptorů jako je aktivita, mobilita a složitost. Hjortovy parametry byly spočítány jak pro EEG, tak také EOG signály. Všechny výpočty byly provedeny pro jednotlivé spánkové fáze (W, REM, N1, N2 a N3).

Tabulka 3 Přehled fází a jejich vhodnosti pro klasifikaci podle statistického vyhodnocení pro získané příznaky v časové oblasti

Získané příznaky	Spánkové fáze			
	Fáze, které se signifikantně liší od ostatních		Fáze, které se signifikantně neliší od ostatních	
	EEG/EMG	EOG	EEG/EMG	EOG
Stř. hod.	/		/	W,REM,N1,N2,N3
Směr. odchyl.		W,REM,N2		N1-N3
Aktivita	W,N3	W	REM,N1,N2	N2-N3,N1-REM
Mobilita	W,REM,N1,N2,N3	N1,N3		REM-N2,W-REM
Složitost	W,REM,N1,N2,N3	W,N2		REM-N1,N1-N3
RMS	W, REM,		W-N1	
EMG Sm. Odchyl.	N1,N2		W,REM,N3	

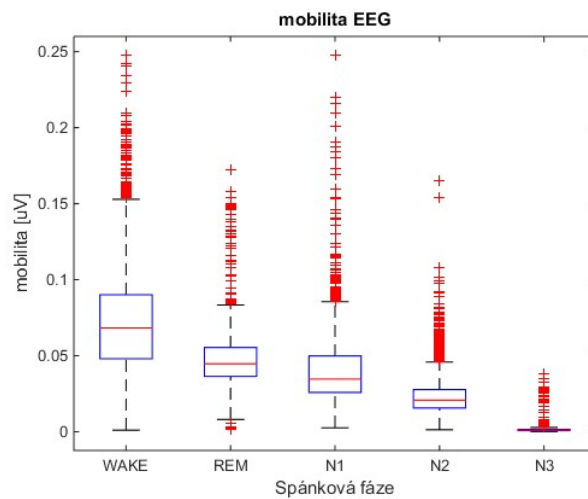
Pro zobrazení a porovnání výsledných hodnot pro jednotlivé fáze bylo využito krabicových grafů zobrazující medián, a rozložení hodnot v prostorech mezi horním a dolním kvantilem. Pomocí krabicových grafů je poté možno usuzovat na základě mediánů a hranic kvantilů, které skupiny se od sebe liší, a jak výrazně, což může také přispět k rozhodování o klasifikovatelnosti jednotlivých skupin.

Na obr. 13 je na ukázkou vykreslen krabicový diagram pro střední hodnoty, kde lze pozorovat výrazné překrytí kvantilů a tedy $p > 0,05$.



Obr. 13 Zobrazení krabicových grafů pro porovnání střední hodnoty jednotlivých spánkových fází

Dalším zobrazením na obr. 14 je poté krabicový diagram pro mobilitu EEG signálu. Zde jsou již vidět odstupy mediánů mezi jednotlivými fázemi s jítým překryvem v oblasti kvartilů s $p < 0,05$. Tento příznak je možné zařadit mezi klasifikovatelné příznaky.



Obr. 14 Graf znázorňující rozložení příznaku mobilitu pro EEG signál v jednotlivých spánkových fázích.

5.2.2 Příznaky ve frekvenční oblasti

Ve frekvenční oblasti získáváme z PSG signálu další skupinu příznaků, kterou je možné začlenit ke klasifikaci vybranými klasifikátory. Ze skupin signálových segmentů, které byly roztrženy dle známého manuálního ohodnocení lékařem, byla extrakce příznaků provedena pro vybraná frekvenční pásma delta, theta, alfa, beta, gamma. Pro frekvenční oblast byl získán odhad spektrální výkonové hustoty v absolutních a zároveň i relativní míře, přičemž relativní hodnoty byly získány vztahem, kdy absolutní PSD ve zkoumaném pásmu podělíme celkovou spektrální výkonovou hustotou všech pásem.


K samotnému výpočtu spektrální výkonové hustoty byla vybrána Welchova metoda zakládající se na rychlé Fourierově transformaci pro získání spektrálních koeficientů. Výkonová spektra získaná Welchovou metodou, byly spočítány pro velikost použitého Hammingova okna s délkou 256 Hz s překrytím oken 50 %. Tato nastavení by měla zajistit získání optimálních hodnot vyhlazeného průběhu spektra.

Jednotlivé vyčleněné příznaky jsou vypsány v přehledové tabulce (Tabulka 4). Zde je možné porovnat, jaké fáze jsou v rámci těchto příznaků klasifikovatelné to jednotlivých tříd. Ačkoliv fáze u některých příznaků nejsou signifikantně odlišitelné, přesto byly zařazeny do trénovací množiny a klasifikace byla s těmito fázemi prováděna.

Tabulka 4 Přehled fází a jejich vzájemné vhodnosti pro klasifikaci podle statistického vyhodnocení pro získané příznaky ve spektrální oblasti


Získané příznaky	Spánkové fáze			
	Statisticky významné fáze		Statisticky méně významné fáze	
	EEG		EEG	
PSD delta	REM,N1		/	
PSD theta	W,REM,N1,N2,N3		/	
PSD alfa	W, REM		N1,N2,N3,	
PSD beta	W		REM, N1,N2,N3	
PSD gamma			W,REM,N1,N2,N3	
Spek. entropie	W,REM,N1,N2,N3		/	

Dalším možným grafickým porovnáním je vykreslení jednotlivých skupin fází do krabicových grafů, na kterých můžeme pozorovat statistické parametry medián a jeho kvantily pro hodnoty např. relativní výkonové spektrální hustoty (Obr. 15).



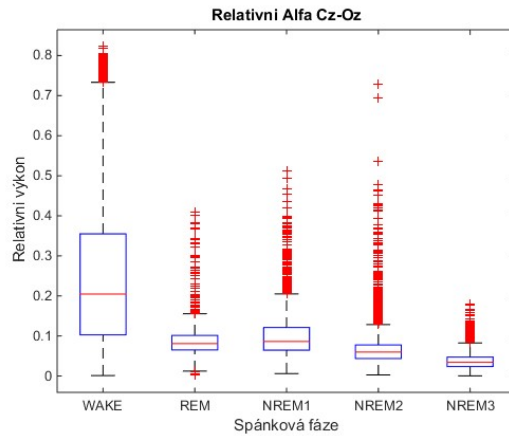
Obr. 15 Zobrazení krabicových grafů pro porovnání spektrální entropie jednotlivých spánkových fází

U frekvenčních pásem delta (obr.16) je možné pozorovat, že spektrální výkonová hustota pro fázi W má mediánovou hodnotu signifikantně nižší než pro ostatní epochy, především lze pozorovat výraznou odlišnost od fáze N3, která je právě pro vlny delta charakteristická, jelikož se jedná o hluboký spánek, tedy převahu nízkofrekvenčních vln. Tato testovaná pásma by měla být dobře klasifikovatelná



Obr. 16 Zobrazení krabicových grafů pro porovnání relativní PSD jednotlivých spánkových fází ve vybraném pásmu delta

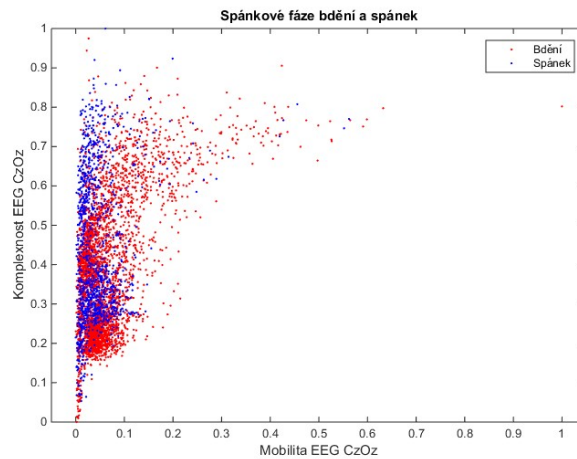
Pro aktivitu alfa, jehož výskyt je typický převážně pro klidové fáze se zavřenými očima, je vidět, že jeho rozlišitelnost PSD není optimální v alfa pásmu, navíc je zde vidět, že větší aktivity dosahovala fáze bdění Wake (Obr. 17).



Obr. 17 Zobrazení krabicových grafů pro porovnání relativní PSD jednotlivých spánkových fází ve vybraném pásmu alfa

5.2.3 Bodové zobrazení

Závislost dvou skupin porovnávaných parametrů je možné zobrazit také pomocí bodových diagramů. Ty nám poskytují informace o rozdělení dat v různých skupinách. Takto lze porovnávat zpravidla dva, popř. i tři příznaky najednou. Pokud je možné pozorovat dramatický vzájemný překryv skupin bodů, bude se pravděpodobně jednat o složité klasifikovatelné skupiny (Obr. 18).



Obr. 18 Ukázka rozložení závislosti shluků příznaků mobilita EEG a komplexnost mezi spánkovými fázemi W a N1-N2-N3.

5.2.4 Vyhodnocení klasifikačních výsledků

Poté co je model neuronové sítě celkově natrénován a otestován potřebujeme zjistit, s jakou úspěšností daná síť dokáže epochy klasifikovat, resp. s jakou výkonností neuronová síť v našem případě pracuje. K tomu je možné využít kontingenční matice, kterou lze sestavit z vypočtených veličin jako je specifická a senzitivita. Počet falešně negativních či pozitivních, nebo skutečně pozitivních či negativních příznaků můžeme zapsat do tabulky, z nichž získáme tzv. konfúzní matici, nebo také matici záměn (viz Tabulka 5). Tyto parametry získáme z následujících vztahů:

$$\text{Senzitivita} = \frac{TP}{TP + FN} \quad (5.1)$$

Senzitivita je údaj dávající informaci o tom, s jakou pravděpodobností (např. s jakou procentuální úspěšností) test přiřadí zkoumaný prvek (v našem případě epochu) do skupiny 1 (bdění) právě z těch prvků, které skupině 1 náleží.

$$\text{Specifická} = \frac{TN}{TN + FP} \quad (5.2)$$

Specifická potom udává správné přiřazení prvku odpovídající skupině 2 (spánek) právě k této skupině. Dalšími parametry, které lze z matice záměn určit je např. celková úspěšnost, která je dána vztahem

$$\text{Úspěšnost} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5.3)$$

A naopak chybovost:

$$\text{Chybovost} = \frac{FP + FN}{TP + TN + FP + FN} \quad (5.4)$$

Tedy TP (angl. *true positive*) značí počet skutečně pozitivních příznaků, FN (angl. *false negative*) je počet falešně negativních příznaků a FP (angl. *false positive*) je počet falešně pozitivních příznaků. Senzitivitu označujeme symbolem Se a podobně specificku Sp .

Tabulka 5 Znáznornění schématu matice záměn

Požadované hodnoty	Predikované hodnoty	
	Předvídaný Pozitivní - skup. 1	Předvídaný Negativní - skup. 2
Správně pozitivní – skup. 1	TP	FN
Správně negativní – skup. 2	FP	TN

6 KLASIFIKACE ANALYZOVANÝCH PSG SIGNÁLŮ

Snahou klasifikace je určit spánkové fáze na základě rozdělení celého spánkového procesu a podle klasifikace AASM. Během celé klasifikace je pak podstatně sledovat, s jakou úspěšností dokáže navržená síť jednotlivé fáze klasifikovat. Parametry klasifikace jsou vybírány na základě předešlé analýzy EEG signálů, přičemž je brán ohled na signifikantně lišící se konkrétní spánkové fáze pro dané příznaky. V celkovém vyhodnocení pak můžou být do klasifikace zahrnuty také všechny analyzované příznaky.

Na úspěšnost klasifikace má značný vliv také samotná architektura umělé neuronové sítě od její typologie, až po počet vrstev, resp. počet neuronů ve skrytých vrstvách. Mezi další parametry, které mají vliv na úspěšnost klasifikace, a které se nabízí k porovnání, patří také různé variace algoritmů zpětného šíření chyby.

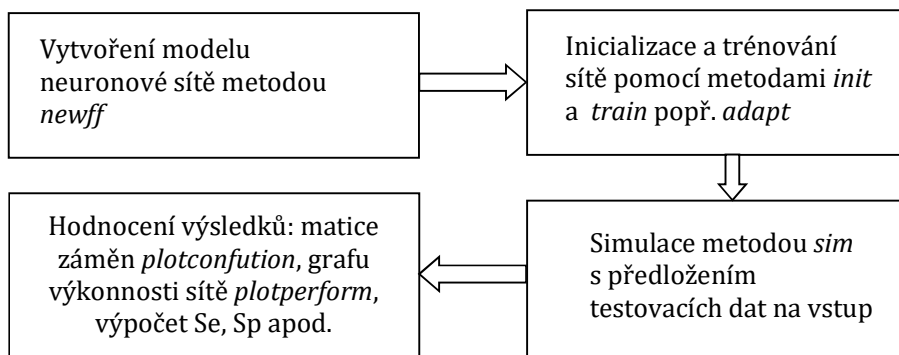
Během praktické části práce se budeme zabývat algoritmy pro trénování sítí a jejich úspěšností během testování. Ověříme teoretické předpoklady. Konkrétněji předpokad, že při porovnání typů metody zpětné propagace chyby, přesněji gradientního algoritmu vůči Levenberg – Marquardt algoritmu bychom měli dospět k rozlišným výsledkům. [23]

Dále při klasifikaci využijeme i dalších vybraných metod, a to metody podpurných vektorů a metodu k-nejbližších sousedů.

6.1 Klasifikace pomocí neuronové sítě

6.1.1 Volba trénovacích dat

Před samotným trénováním je velice důležitá volba učící a testovací množiny. Ta vychází z předcházející analýzy signálů a výběru vhodných příznaků, které co nejúplněji a nejpřesněji popisují charakteristické rysy úlohy. Dalším kritériem je určení optimálního počtu příznaků. Důležitost volby odráží časovou náročnost během zpracování sítí a také z hlediska generalizace, tedy schopnosti neuronových sítí správně klasifikovat i ty vstupní vzory, které nejsou součástí trénovací množiny.



Obr. 19 Diagram postupu při návrhu, trénování a procesu testování neuronové sítě se zpětným šířením chyby

6.1.2 Návrh neuronové sítě pro klasifikaci

V prvopočátku návrhu neuronové sítě je třeba provést rozvahu ohledně toho, kolik bude síť obsahovat vrstev, kolik bude neuronů ve skryté vrstvě, jakou zvolit učební metodu a kritéria zastavení učení atd. U skrytých vrstev se standardně využívá jedné až dvou skrytých. Vše záleží na dané úloze, kterou chceme se sítí řešit.

Tabulka 6 Příklad binárního kódování výstupu pro případ 3 výstupních neuronů (kódování jednotlivých spánkových fází pomocí 1 a 0)

Spánková fáze	W	REM+N1	N1+N2
neuron 1	1	0	0
neuron 2	0	1	0
neuron 3	0	0	1

Volba počtu vstupních neuronů ve vstupní vrstvě je závislá na počtu příznaků ve vstupním datasetu. Počet neuronů ve výstupní vrstvě volíme podle toho, do kolika skupin budeme chtít data klasifikovat, tedy v našem případě, do kolika

spánkových fází. K lepšímu znázornění nám pomůže přehledová tabulka (Tabulka 6) znázorňující kódování výstupu sítě, kde řádky znamenají k -tý výstupní neuron a sloupce spánkovou fází, kterou chceme klasifikovat dle námi zvolených příznaků na vstupu sítě.

Počet skrytých neuronů obsažených ve skryté vrstvě se pohybuje zpravidla v rozmezí počtu vstupních a výstupních jednotek. V případě volby velkého počtu skrytých jednotek, může trénování sítě vést k přeučení a nekorektním výsledkům testů. Je-li ale počet skrytých naopak neuronů příliš malý, může být natrénování sítě obtížné. Správnost natrénování sítě lze hodnotit celkovou klasifikací experimentu. Pokud síť dosahuje dobrých výsledků při tréninku, a zároveň špatných výsledků během testování, množství skrytých neuronů by se mělo snížit. Opačně, pokud se stane, že síť produkuje špatné výsledky v procesu trénování, počet skrytých neuronů by se mohl navýšit. [23]

6.1.3 Trénování neuronové sítě

Pro vytvoření vícevrstvé dopředné neuronové sítě použijeme v Matlabu příkaz *newff* (obr. 19), díky němuž můžeme vytvořit strukturu dítě *net*. Ta se skládá z informace ohledně vstupu sítě (můžeme využít informace o rozsahu hodnot vstupů), dále z cílových vektorů, které budou při trénování přivedeny na výstup. V parametru *Layers* pak nastavujeme počty neuronů v jednotlivých vrstvách a transformační funkce neuronů zadáme přes parametr *TransFcns*. Výsledný zápis pro vytvoření sítě pak může vypadat následovně:

```
Class net = newff( inputDataset, targetDataset, [10], {'logsig','purelin'} ), 'trainlm',  
'mse');
```

přičemž *inputDataset*, *targetDataset* jsou vstupní a požadované výstupní hodnoty, atribut [10] znamená, že skrytá vrstva obsahuje 10 neuronů. Parametry {'logsig','pureline'} udávají aktivační funkci sítě pro skrytou vrstvu a výstupní vrstvu. 'trainlm' a 'learnqdm' znamená, že je využito trénování se sítě se zpětnou propagací chyby a 'mse' udává chybovou funkci (mean squared error). Možné trénovací funkce jsou vypsány v Tabulce 7.

Vlastní proces trénování se spouští pomocí příkazu *train()*. Vstupními a výstupními parametry jsou námi předem sestavené matice všech klasifikovaných spánkových epoch. V trénovací matici, která je deklarována jako druhý parametr funkce *train()* je určeno kódování jednotlivých výstupů tak, aby klasifikovaným epochám byla přidělena klasifikační skupina

Jelikož standardní *back propagation* algoritmus má sklony ke konvergenci k lokálnímu minimu, proto v rámci stabilizace chybové funkce učícího algoritmu v oblasti lokálního minima, patří mezi nastavitelné parametry sítě tzv. *moment* (*angl. momentum*) a adaptivní *krok učení* (*angl. adaptive learning rate*). Učící algoritmus díky těmto parametrům by měl být schopen nalézt globální minimum pro celou síť, a tím se snížit citlivost učení na detaily chybové funkce, a zamezit uvíznutí v lokálním minimu. Dovoluje také síti odpovídat na lokální gradient a sledovat trend chybové křivky. S tím také souvisí optimalizace času potřebného na natrénování sítě. Parametr *Net.trainParam.lr* tedy udává krok učení a zároveň také, jak moc se mají měnit koeficienty vah. Nastavení parametru *Net.trainParam.epochs* udává počet epoch, v nichž se bude síť trénovat. Nastavením parametru *net.trainParam.goal* udáváme požadovanou chybu během trénování. Nejčastěji se volí střední kvadratická chyba *mse* (*mean squer error*). [23]


Tabulka 7 Přehled optimalizačních metod a jejich parametrů pro síť typologie se zpětným šířením chyby

Zkratka	Název trénovací funkce pro UNS
traingd	Gradientní funkce
traingdm	Gradientní funkce s momentem
traingda	Gradientní funkce s adaptivním učebním poměrem
traingdx	Gradientní funkce s adaptivním učebním poměrem a momentem
trainlm	Levenberg-Marquard optimalizace vah
trainrp	Pružné učení
trainscg	Funkce konjugovaných gradientů
trainbfg	Bayesovské pravidlo

Při procesu trénování se váhy a prahy neuronů nastavují po proběhnutí celé sekvence všech vektorů vstupů. Jinou možností je použití funkce *adapt*, kdy se váhy a prahy neuronů nastavují po každé jednotlivé předložení na vektoru vstupu.

Trénovací dataset vytvoříme tak, aby měla vstupní matice počet řádků podle toho, kolik příznaků je do klasifikace zahrnuto. V našem případě bude mít matice 16 řádků a celkem 15996 sloupců. Tedy na začátku je nutné si určit, kolik a jaké fáze budeme rozlišovat. Podle toho volíme počet výstupních neuronů. Pro případ rozlišení do dvou skupin nám bude stačit pouze jeden výstupní neuron k binární klasifikaci. Chceme-li rozlišit klasifikaci na tři spánkové fáze (W, REM+N1, N2+N3), zvolíme podle tři výstupní neurony, a tedy výstupní matice bude obsahovat tři řádky každý pro jeden výstupní neuron. Schématické znázornění modelované sítě můžeme vidět na obrázku (obr. 20) tak jak i zobrazuje toolbox v Matlabu. Při návrhu

sítě je třeba určit kódování hodnot ve výstupní matici a podle toho také volit přenosové funkce neuronů ve vrstvách. V našem případě jsme mezi skrytou a výstupní vrstvou vložili funkci *purelin* (lineární). Tato funkce umožňuje rovnoměrné rozprostření hodnot od minusových až po plusové. Při výsledném vyhodnocení je třeba tyto hodnoty zaokrouhlit, tak aby odpovídaly rozsahům daným klasifikačních skupin, které jsou určeny pomocí známých výstupních matic, v našem případě 0 a 1 pro každý výstupní neuron.




Obr. 20 Vizualizace simulace trénování sítě pro 2 skryté vrstvy (Matlab Neural Network toolbox), a s třemi výstupními neurony pro klasifikaci do třech fází

Jakmile dojde k natrénování sítě, je možné síť ověřit pomocí testovacího procesu. Síti jsou předloženy vybrané testovací signály, které byly vyčleněny ještě před začátkem trénování sítě čistě pro tento proces, tedy se neúčastní trénovacího procesu, a tvoří cca 20 % z celkového objemu vstupních dat. Pomocí příkazu *sim* nasimulujeme chování sítě. Získané výsledky poté můžeme vyhodnotit pomocí matice záměn. Tu lze vykreslit funkcí *plotconfusion*, která graficky znázorní na základě správných požadovaných hodnotách procentuální úspěšnosti klasifikace sítě (Obr. 21).



Obr. 21 Znázornění matice záměn získané vykreslením výsledků klasifikace v programu Matlab

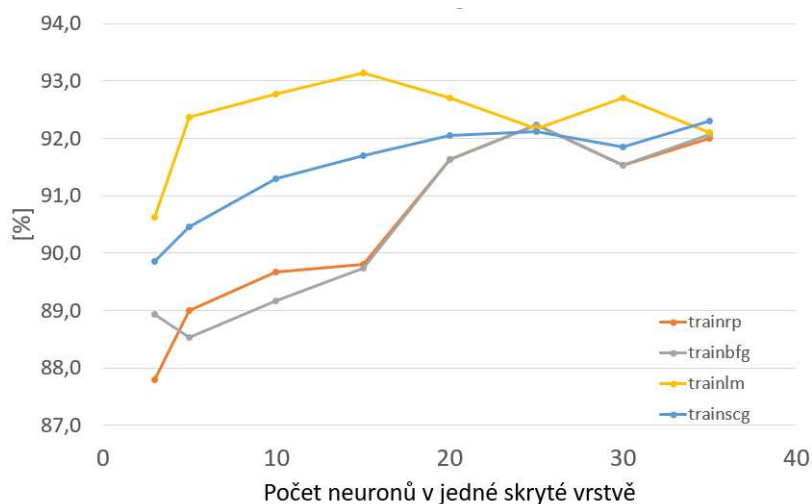
Čísla na hlavní diagonále konfúzní tabulky udávají absolutní četnost správného rozpoznání vzorku z množiny příznaků. Čísla mimo diagonálu znamenají počet chybných klasifikací. V matici tedy můžeme vidět, kolik bylo správně přiřazených vzorků podle skupin a kolik vzorků bylo naopak přiřazeno špatně. V prvním sloupci vidíme, že bylo z celkového počtu 2691 testovaných vzorků správně pro první skupinu 1155 vzorků klasifikováno 1034 vzorků tedy 89,5 % a chybně potom 62, resp. 59 vzorků tedy 10,5 %. Takto získáme procentuální vyjádření o úspěšnosti zařazení pro každou třídu, a následně také celkovou úspěšnost klasifikace, resp. přesnost celé sítě, v tomto případě 88,9 %.



Obr. 22 Znárodnění závislosti počtu neuronů pro 2 skryté vrstvy neuronové sítě a procentuální úspěšnost její klasifikace do tří fází W, REM, N3 na typu zvoleného trénovacího algoritmu

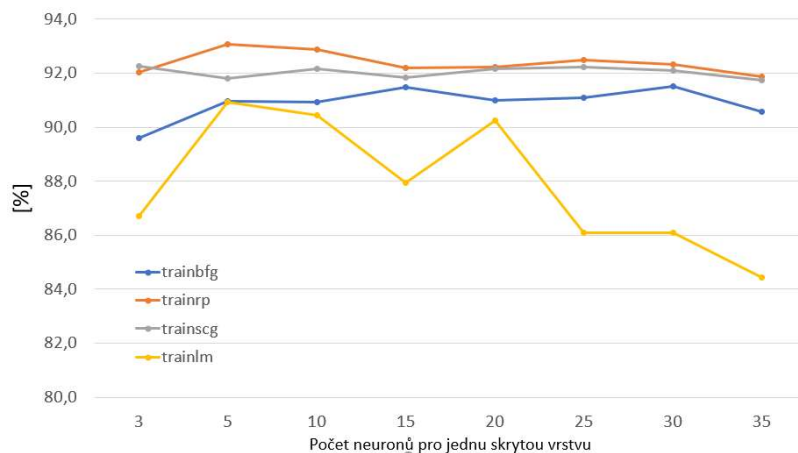
Na obr. 22 je znázorněn výsledek klasifikace pomocí neuronové sítě, která byla tvořena pomocí dvou skrytých vrstev. Graf ukazuje vývoj úspěšnosti na základě počtu neuronů jak v první, tak také v druhé vrstvě. Klasifikace byla provedena dotří fází W, REM, N3 Zde můžeme vidět, že nejlépe si algoritmus *trainlm* (Levenberg-Maquardtův). Ačkoliv jeho doba trvání během klasifikace delší než oproti algoritmu *trainscg* nebo *trainrp*.

Pro další testování byla použita neuronová síť pouze pro jednu skrytou vrstvu, která klasifikovala fáze W, REM a N3. Úspěšnost klasifikace mezi těmito fázemi je graficky znázorněno na obr 23. Je zde vidět opět procentuální vývoj jednotlivých trénovacích algoritmů v závislosti na počtu neuronů ve skryté vrstvě. Nejlepší skóre má zde opět algoritmus *trainlm*, přičemž u všech ostatních algoritmů je vidět, že s počtem neuronů roste také úspěšnost klasifikace.



Obr. 23 Graf závislosti procentuální úspěšnosti klasifikace jednotlivých trénovačích funkcí do tří fází W, REM, N3 a spánek na počtu neuronů.

V posledním testu byla vstupní data klasifikována do dvou skupin, a to do fáze W a spánku, která zahrnovala ostatní fáze REM, N1, N2, N3. Opět u tohoto modelu byla nastavena pouze jedna skrytá vrstva. Úspěšnost klasifikace mezi těmito fázemi je graficky znázorněno na obr 24. Je zde vidět opět procentuální vývoj jednotlivých trénovačích algoritmů v závislosti na počtu neuronů ve skryté vrstvě. Maximální počet neuronů je nastaven na hodnotu 35.

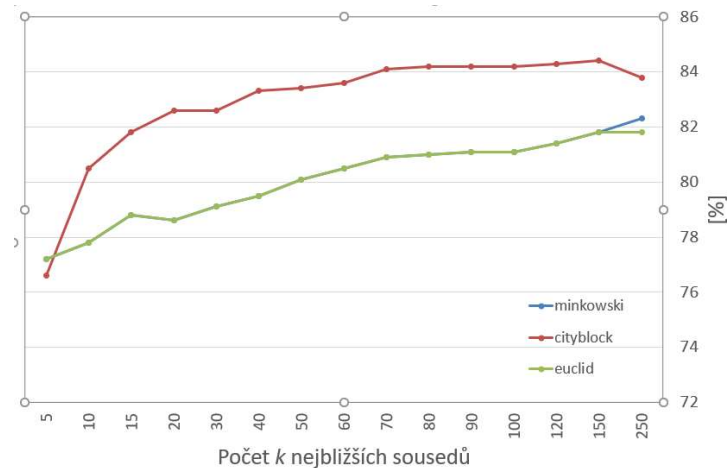


Obr. 24 Graf závislosti procentuální úspěšnosti klasifikace jednotlivých trénovačích funkcí při klasifikaci do dvou fází bdělost a spánek na počtu neuronů.

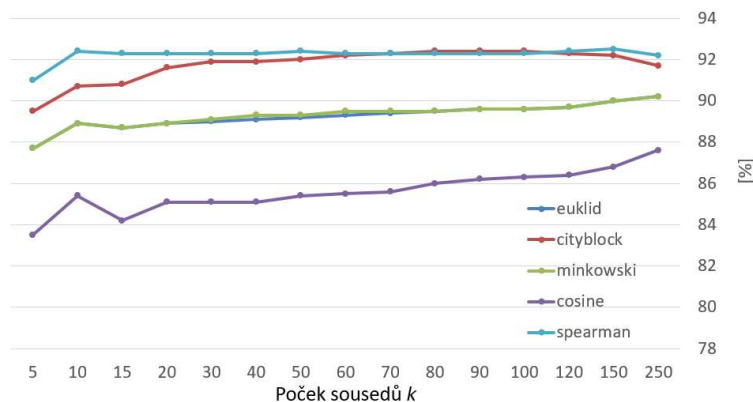
6.2 Klasifikace K-NN klasifikátorem

Další zvolenou klasifikační metodou byla metoda KNN (K-nejbližších sousedů). V programovém prostředí Matlab byl definován trénovací klasifikační model vytvořením instance třídy *ClassificatinKNN*. Třída obsahuje potřebné parametry, které je možné nadefinovat pro chod modelu, jako je požadovaná metrika a počet nejbližších sousedů. Z nich se poté bude odvozovat daná skupina příslušnosti. Na tento model pak byl aplikován vstupní dataset pro natrénování modelu metodou *fitcknn*, která umožňuje provést klasifikaci do více skupin. Samotné výsledky klasifikace lze získat pomocí metody *predict*, která po předložení testovací skupiny vrátí vektor příslušnosti k jednotlivým skupinám pro vstupní data. Z tohoto vektoru lze poté odvodit úspěšnost klasifikace do daných skupin dle matice záměn. Pomocí KNN klasifikátoru byla vyhodnocována předložená data do dvou skupin bdění/spánek, a poté také do tří skupin bdění, REM, N1+N2+N3 fáze. Výsledky klasifikace byly shrnuty do Tabulky 10 (viz Příloha 1), kde je uvedena jejich procentuální úspěšnost dle zvolené vzdálenostní metriky a počtu sousedů funkce.

Na Obr. 25 a Obr. 26 je možné vidět vývoj procentuální úspěšnosti klasifikace v závislosti na počtu k sousedů a vybraných metrikách klasifikátoru. Klasifikace probíhala mezi fázemi bdění (W) a spánek a v druhém případě se jednalo o fáze bdění (W), fázi REM a spánkovou fázi N3. Z grafu je patrné, že celková úspěšnost klasifikace se s rostoucími počty sousedů postupně zvyšuje, přičemž strmost růstu závisí na zvolené metrice. Horní limitní nastavenou hodnotou parametru k bylo 250.



Obr. 25 Znárodnění procentuální úspěšnosti klasifikace do skupin W, REM, N3 v závislosti na počtu sousedů pro vybrané klasifikační metriky



Obr. 26 Znáznornění procentuální úspěšnosti klasifikace do skupin W, REM+N1+N2+N3 (bdění a spánek) v závislosti na počtu sousedů pro vybrané klasifikační metriky

6.3 Klasifikace SVM klasifikátorem

Poslední klasifikační metodou byla zvolena metoda podpůrných vektorů SVM. V programovém prostředí Matlab byl madefinován trenovací klasifikační model vytvořením instance třídy *TemplateSVM*, v rámci které je možné nadefinovat příslušné parametry modelu, např. jádro funkce (*KernelFunction*). Na tento model pak byl aplikován vstupní dataset pro natrénování modelu metodou *fitcecoc*, díky které je možné klasifikovat do více než dvou skupin. Samotné výsledky klasifikace lze získat pomocí metody *predict*, která po předložení testovací skupiny dat vrátí vektor příslušnosti k jednotlivým skupinám. Z toho lze poté odvodit úspěšnost klasifikace do daných skupin dle matice záměn. Pomocí tohoto klasifikátoru byla vyhodnocována předložená data do dvou skupin bdění/spánek a poté do tří skupin Wake, REM, N1-N2-N3 fáze. Výsledky klasifikace byly shrnuty do Tabulky 8, kde je uvedena jejich procentuální úspěšnost dle zvolené jádrové funkce.

Tabulka 8 Tabulka výsledků klasifikace pro určené spánkové fáze klasifikátorem K-NN

SVM	Klasifikace do spánkových fází					
	Jádrová funkce	W/REM-N1-N2-N3		W/REM/N1-N2-N3		
		[%]		[%]		
	gaussian	89,6	77,7	90,2	9,7	84,1
	linear	89,4	83,6	89,5	39,4	86,4
	rbf	89,5	77,3	91,2	8,4	78,9
	polynom 1.st	89,4	83,4	89,4	38,4	86,6
	polynom 2.st	80	94,6	80,6	56,1	92,8
	polynom 3.st	0	100	0,1	0	100

Z tabulky je patrné, že úspěšnost klasifikace pro fázi REM je velice malá. Další provedenou klasifikací pomocí SVM modelu byla klasifikace do tří samostatných skupin W, REM, N3. Výsledky jsou podrobně uvedeny v přehledové tabulce (Tabulka 9). Tabulka je také doplněna o údaje celkové úspěšnosti klasifikace. Navíc je zde pozorovatelné zlepšení klasifikace pro fázi REM.

Tabulka 9 Tabulka výsledků klasifikace pro určené spánkové fáze W , REM, N3 pomocí klasifikátoru SVM

Klasifikace SVM	Klasifikace do spánkových fází				
	Jádrová funkce	W	REM	N3	Celková úspěšnost
	[%]				
	gaussian	92,9	74,7	97,6	89,8
linear	88,0	82,0	99,6	90,1	
rbf	93,1	73,5	97,9	89,6	
polynom 1.st	88,3	81,7	99,5	90,2	
polynom 2.st	92,6	78,5	99,6	91,2	
polynom 3.st	91,0	75,9	19,7	64,7	

7 ZÁVĚR

Úkolem této diplomové práce byl návrh a realizace postupu pro automatickou klasifikaci spánkových fází s využitím polysomnografických dat. Před samotnou klasifikací byl proveden teoretický rozbor informací zeměřených na samotná spánková stádia a na jejich detailnější vazby, ať již se to týká průběhu spánku, nebo kvlivu na průběh vybraných signálů snímaných v rámci polysomnografických měření, především se jedná o signály EEG, EOG, EMG.

Celkem bylo vybráno 24 signálů získaných z databáze ÚBMI, a tyto signály byly následně podrobeny analýze za účelem extrahování příznaků sloužící pro účely klasifikace. Jako klasifikační příznaky byly vybrány příznaky jak z časové oblasti, tak také z frekvenční oblasti díky převodu signálu do frekvenční oblasti za pomoci rychlé Fourierově transformaci. přičemž jednotlivé příznaky byly vždy vztaženy k 30 ti sekundovým epochám signálů. Příznaky pak byly graficky vykresleny a porovnány. V dalším kroku se určilo za pomoci statistického testu ANOVA a post-hoc testu, který určil, jaké příznaky jsou vhodné pro postoupení ke klasifikaci čili jsou od sebe rozlišitelné.

Jako klasifikátory byla vybrána trojice klasifikačních modelů založených na metodách K-NN, VSM a umělých neuronových sítích. Testování nebylo prováděno na celé dávce zpracovaných signálů, ale pouze části, která nebyla zahrnuta do trénovacího procesu. Porovnáním úspěšnosti klasifikace bylo zjištěno, že nejlépe dokáže na vybraných signálech provést klasifikaci neuronová síť s jednou skrytou vrstvou, a to v případě klasifikace do třech samostatných fází W, REM, N3.

Pro klasifikaci neuronovou sítí byla využita topologie sítě s dopředným šířením chyb (tzv. back propagation) s několika nastaveními jejich parametrů převážně počtem neuronů, počtem skrytých vrstev a trénovací funkcí. Jako stěžejní pro dosažení optimálních výsledků klasifikace se ukázal být počet neuronů ve skryté vrstvě. Z navrhovaných skupin neuronů byla nejúspěšněji natrénována síť s počtem 15 neuronů pro jednu skrytou skryté vrstvu. Z naměřených hodnot také vyplývá, že v případě dvou skrytých vrstev, má úspěšnost klasifikace zvyšující se tendenci s rostoucím počtem neuronů v obou vrstvách. Na druhou stranu ovšem narůstá také doba potřebná pro klasifikaci.

Klasifikace byla provedena jako postupný rozklad do několika úrovní dle zkoumaných spánkových fází. První klasifikace proběhla do dvou skupin, fáze bdění a spánku, v další úrovni proběhla klasifikace do tří skupin, fáze bdění, REM a ostatních spánkových fází dohromady. Dle získaných hodnot úspěšnosti klasifikace,

které jsou uvedeny v tabulkách jednak v rámci hlavního textu, tak také v příloze, lze vyhodnotit, že na výsledek klasifikace mají vliv nejen samotné parametry jednotlivých modelů, ale také počet příznaků ve vstupní matici. Dle výsledků úspěšnosti klasifikace samostatné fáze REM by stálo za úvahu, k této fázi připojit spánkovou fázi N1, do které REM přechází a jsou tedy od sebe hůře klasifikovatelné.

LITERATURA

- [1] JAN J. *Číslicová filtrace, analýza a restaurace signálů*, 2. vydání: Vysoké učení technické v Brně, 2002. 427 a. ISBN 80-214-2911-9.
- [2] SORNMO L, LAGUNA P. *Bioelectrical signal processing in cardiac and neurological applications*. Elsevier Academoc Press, rok.
- [3] ANDERER P., MOREAU A. *Computer-Assisted sleep classification according to the standard of, American Academy of Sleep Medicine*, Neuropsychobiology Neuropsychobiology 2010, p. 250 - 264
- [4] GUNES S., POLAT G., YOSUNKAYA A. *Efficient sleep stage recognition systém based on EEG signal using k-means clusterisng based feature weightining*, Selcuk University, Turkey, 2010, p.7922-7928
- [5] EOH J.H., CHUNG K.M., KIM H.S. *Electroencephalographic study of drowsiness in simulated driving with sleep deprivation*, Pohang, p.307 - 320
- [6] RONZHINA M. *Klasifikace mikrosnánku analýzou EEG*. Diplomová práce. Brno: Vysoké učení technické v Brně, 2009.
- [7] RIEGER J., LHOTSKA L.,KRAJČA V. *Zpracování dlouhodobých EEG záznamů*, České vysoké učení technické v Praze, [cit. 13-12-20] dostupné z WWW na: <http://advances.utc.sk/index.php/AEEE/article/view/257/300>
- [8] OROPESA E., CYCON L.H., JOBERT M. *Sleep stage classification using wavelet transform and neural network*, California, 1999,[cit 13-12-25]
- [9] 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.
- [10] PIRYATINSKA A., TERDIK G. Et al. *Automated detection of neonate EEG sleep stages*, COMM-2880 [cit 13-12-2]
- [11] PENZEL T., CONRAD R, *Computer based sleep recording and analysis*, 2000, č.40, s. 131-148, Mardburg, [cit 14-01-04]
- [12] CARDOSO E., BATISTA A. et al. *A contribution fot the automatic sleep classification based on the Itakura-Satio spectral distance*, Portugal, [cit 13-11-25]
- [13] GERLA V., LHOTSKÁ L., *Trendy ve zpracování eeg*, 2008, s. 11, dostupné z WWW na: <https://cyber.felk.cvut.cz/research/theses/papers/280.pdf>
- [14] UHLÍŘ, Jan a Pavel SOVKA. *Číslicové zpracování signálů*. Vyd. 2. přeprac. Praha: Vydavatelství ČVUT, 2002. ISBN 80-01-02613-2.
- [15] *Neuronové sítě* [online]. Brno Mendelova Univerzita v Brně Dostupné z: http://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=21471

- [16] BARLOW, John S. *The electroencephalogram: its patterns and origins*. Cambridge, Mass.: MIT Press, c1993. ISBN 0262023547.
- [17] KRAJČA, Vladimír a Jitka MOHYLOVÁ. *Číslíkové zpracování neurofyziologických signálů*. V Praze: České vysoké učení technické, 2011. ISBN 978-80-01-04721-7.
- [18] VOJTĚCH, Zdeněk. *EEG v epileptologii dospělých*. Praha: Grada, 2005. ISBN 80-247-0690-3.
- [19] LIU Y., YAN L., *Automatic Sleep Stage Scoring using Hilbert-Huang Transform with BP Neural Network*, Lanzhou University. China. 2008. 2008:3848-51.
- [20] RONZHINA M., JANOUSEK O., KOLAROVA J., *Sleep scoring using artificial neural network*, Sleep Medicine Reviews 16. 2012
- [21] YUCELBAS C., OZSEN SERAL., GUNES S. *Effect od some power spectral density estimation methods on automatic sleep stage scoring using artificial neural network*, IADIS Vol.8 No. 2, s. 119-131. ISSN: 1646-3692
- [22] KOZUMPLIK, J., KOLAR, R., JAN, J. *Číslíkové zpracování a analýza signálů. Počítačová cvičen, (Elektronická skripta, BMI102)*. Brno: FEKT VUT v Brně, 2003. s. 1- 85. ISBN: BMI 102
- [23] OREL, Miroslav a Roman PROCHÁZKA. *Vyšetření a výzkum mozku: pro psychology, pedagogy a další nelékařské obory*. Praha: Grada, 2017. Psyché (Grada). ISBN 978-80-247-5539-7.
- [24] TUČKOVÁ, Jana. *Vybrané aplikace umělých neuronových sítí při zpracování signálů*. Praha: České vysoké učení technické v Praze, 2009. ISBN 978-80-01-04229-8. OREL M., PROCHAZKA R., *Vyšetření a výzkum mozku. Pro psychology, pedagogy a další nelékařské obory*. Praha, 2017. s.168.
- [25] MOLNÁR, Karol. *Úvod do problematiky umělých neuronových sítí*. Elektrovue [online]. 2000 [cit. 2016-05-15]. ISSN ISSN 1213-1539. Dostupné z:
- [26] KVASNIČKA, Vladimír. *Úvod do teórie neurónových sietí*. Slovenská republika: IRIS, 1997. ISBN 80-88778-30-1.
- [27] *Učebnice rádiové komunikace* [online]. Brno: FEKT VUT [cit. 2019-05-05]. Dostupné z: <http://www.urel.feec.vutbr.cz/MTRK/>

- [28] MOLNÁR, Karol. *Úvod do problematiky umělých neuronových sítí* [online]. Brno UTKO FEI VUT [cit. 2019-05-10].
Dostupné z: <http://www.elektrorevue.cz/clanky/00013/index.html>
- [29] VOLNÁ, Eva. *Neuronové sítě 1*. Elektronická skripta. Ostrava Ostravská Univerzita v Ostravě, 2008, s. 87.
- [30] KOZUMPLÍK, J. *Analýza biologických signálů*. Skripta UBMI FEKT VUT v Brně, Brno, 2012
- [31] KASAL, Pavel a Štěpán SVAČINA. *Lékařská informatika*. Praha: Karolinum, 1998. ISBN 80-7184-594-9.

SEZNAM SYMBOLŮ, VELIČIN A ZKRATEK

f	Signál v časové oblasti
F	Signál ve frekvenční oblasti
DFT	angl. Discrete Fourier Transform, diskrétní Fourierova transformace
FT	angl. Fourier Transform, Fourierova transformace
STFT	angl. Short-Time Fourier Transform, krátkodobá diskrétní transformace
AASM	angl. American Academy of Sleep Medicine, standardy AASM
R&K	angl. Rechtschaffen and Kales
EEG	Elektroencefalografie
REM	angl. Rapid eye movement
NREM	angl. NON-Rapid eye movement
N2	spánková fáze NON-REM2
N3	spánková fáze NON-REM3
Hz	Hertz
Cz	Nepárová centrální elektroda EEG
Oz	Nepárová okcipitální elektroda EEG
E2	Elektroda EOG signálu
ANOVA	Analýza rozptylu
F_{vz}	Vzorkovací frekvence
σ_i	Směrodatná odchylka i -té derivace signálu
σ_i^2	Rozptyl i -té derivace signálu
$S_{ff}(\omega)$	Výkonové spektrum
H0	Vzorek signálu EEG
H1	Výkonové spektrum
H2	Vzorek signálu EEG
PSG	Polysomnografie

8 PŘÍLOHA

Příloha 1

V této příloze lze nalézt tabulky úspěšnosti klasifikace, která byla provedena pomocí umělé neuronové sítě a metodou K-NN nejbližších sousedů. Tabulka 10 ukazuje hodnoty výsledků klasifikace na základě trénovací funkce neuronu a počtu neuronů ve skrytých vrstvách do jednotlivých fází. Klasifikace zde probíhala do fází W,REM,N1-N2-N3.

Tabulka 10: Přehled výsledků klasifikace do tří spánkových fází W/REM/N1-N2-N3 a 15 vstupních příznaků získané pomocí neuronové sítě.

Trénovací algoritmus		<u>trainrp</u>	<u>trainbfg</u>	<u>trainscg</u>
počet neuronů	Klasifikační skupina	Úspěšnost [%]		
15-5	Wake	87,0	83,1	77,8
	REM	59,7	59,9	59,2
	N1-N2-N3	86,5	91,0	94,1
	celkem	82,7	84,6	85,1
15-10	Wake	83,8	77,0	79,9
	REM	52,2	45,8	46,5
	N1-N2+N3	91,4	95,6	96,4
	celkem	84,0	83,7	85,0
10-2	Wake	83,8	82,4	76,4
	REM	60,6	47,4	48,3
	N1N2-N3	90,1	93,2	96,6
	celkem	84,3	83,9	84,6
10-5	Wake	81,7	75,8	77,4
	REM	57,3	44,3	48,7
	N1-N2-N3	90,4	95,1	95,1
	celkem	83,4	83,1	84,0
20-5	Wake	87,6	79,5	81,5
	REM	58,6	51,2	45,1
	N1-N2-N3	90,7	94,4	96,1
	celkem	85,3	84,5	85,1
30-5	Wake	82,0	83,4	78,8
	REM	40,0	44,6	56,3
	N1-N2-N3	94,5	93,7	95,0
	celkem	83,5	84,0	85,3

Tabulka 11 ukazuje výsledky klasifikace fází bdění W a spánek a W,REM, N1-N2-N3.

Tabulka 11 Tabulka výsledků klasifikace pro určené spánkové fáze klasifikátorem K-NN s vybranými typy metrik

K-NN	Počet sousedů	Klasifikace do spánkových fází				
		W	REM-N1- N2-N3	W	REM	N1-N2-N3
Metrika		[%]		[%]		
Euklid	10	83,2	91,5	86,3	42,6	82,5
	30	83,5	92,3	85,4	40,4	87,1
	50	83,5	92,8	85,5	39,8	89,0
	80	82,9	93,3	85,0	39,7	90,1
	100	82,9	93,8	85,1	40,0	90,7
	150	82,1	93,8	84,7	40,1	92,1
Seuklid	10	85,1	90,9	87,6	33,6	85,4
	30	82,6	92,7	86,6	28,9	89,7
	50	83,7	91,9	86,2	28,9	91,0
	80	83,0	92,7	85,4	26,7	93,0
	100	82,6	92,7	85,2	27,0	93,8
	150	81,6	93,3	84,4	26,5	94,5
	200	81,2	94,0	83,7	26,0	94,9
Cosine	10	84,8	88,6	87,4	43,8	79,5
	30	85,7	88,0	86,9	42,6	82,0
	50	85,1	88,4	86,8	41,7	83,5
	80	85,0	89,0	86,7	42,2	84,3
	100	84,3	89,3	86,5	40,8	85,0
	150	83,9	90,2	86,3	40,4	86,5
cityblock	10	82,8	93,8	85,6	49,3	85,7
	30	83,8	94,6	85,3	48,8	89,9
	50	92,0	94,8	84,6	48,8	91,0
	80	83,2	95,2	84,4	48,1	92,1
	100	82,3	95,3	84,2	47,5	92,6
	150	81,8	95,8	83,8	46,9	93,3
	180	81,0	96,0	83,1	46,5	93,6
Minkowski	10	83,2	91,5	86,3	42,6	82,5
	30	83,5	92,3	85,4	40,4	87,1
	50	83,5	92,8	85,5	39,8	89,0
	80	82,9	93,3	85,0	39,7	90,1
	100	82,9	93,8	85,1	40,0	90,7
	150	82,1	93,8	84,7	40,1	92,1

