

Klasifikace spánkových fází pomocí PSG dat

Classification of sleep stages using PSG data

Martin Králík¹, Marina Ronzhina¹, Miloš Bělhrad²

{xkrali18,xronzh00}@stud.feec.vutbr.cz, milos.belehrad@fnusa.cz

¹Fakulta elektrotechniky a komunikačních technologií VUT v Brně

²Fakultní nemocnice u sv. Anny v Brně - Mezinárodní Centrum Klinického Výzkumu

DOI: -

Abstract: This article is focused on the classification of sleep stages, using PSG data. The data used for the classification come from real patients, signals used are EEG, EOG and EMG. Extraction of classification features is focused on achieving higher than conventional temporal resolution of sleep scoring. This approach could be helpful in sleep disorders diagnostics. Classifiers selected are artificial neural networks. Success rate of classification varies, depending on sleep phase, with W, N3 and REM phases being most successful.

Klasifikace spánkových fází pomocí PSG dat

Martin Králík¹, Marina Ronzhina¹, Miloš Bělhrad²

¹Fakulta elektrotechniky a komunikačních technologií VUT v Brně
Email: {xkrali18,xronzh00}@stud.feec.vutbr.cz

²Fakultní nemocnice u sv. Anny v Brně - Mezinárodní Centrum Klinického Výzkumu
Email: milos.belehrad@fnusa.cz

Abstrakt – Tento článek je zaměřen na klasifikaci spánkových fází za použití polysomnografických dat. Data použitá pro klasifikaci pocházejí od reálných pacientů, použity jsou signály EEG, EOG a EMG. Extrakce klasifikačních příznaků probíhá tak, aby bylo dosaženo vyššího než konvenčního časového rozlišení pro skórování spánku, což by mohlo pomoci diagnostikovat některé choroby spojené se spánkem. Jako klasifikátor jsou zvoleny umělé neuronové sítě. Dosažená úspěšnost klasifikace se pak liší v závislosti na spánkové fázi, s vyššími hodnotami úspěšnosti pro fáze W, N3 a REM.

1 Úvod

Spánek je důležitou součástí života člověka. V dnešní době na nás působí množství negativních vlivů, jako jsou stres, špatné stravování, nezdravé stravování či léky. Tyto vlivy pak mají za následek krátký, nekvalitní nebo dokonce žádný spánek. Výsledkem jsou spánkové poruchy, jako nespavost, narkolepsie nebo spánková apnoe [1].

Počátky výzkumu spánku se datují do 30. let 20. století a jsou spojeny s prvními záznamy elektrické aktivity mozku - elektroencefalogramu (EEG) a prvním rozdělením spánku na spánkové fáze [1]. Během následujících 70 let zaznamenala spánková medicína dva důležité milníky. Prvním byl manuál Rechtschaffen a Kales (R&K) v roce 1968, který určil první standard pro klasifikaci spánku. Druhým pak byl manuál Americké akademie spánkové medicíny (AASM), která vyvinula v letech 2004 až 2006 nový manuál, podle kterého se provádí klasifikace spánku dodnes [1, 2].

V klinické praxi klasifikaci spánkových dat provádí manuálně lidský expert. Taková klasifikace je jednak časově náročná (vyhodnocení jednoho osmihodinového záznamu trvá 2–4 hodiny) a navíc je značně subjektivní - shoda mezi dvěma experty se pohybuje v rozmezí 80–85 % [2]. Z těchto důvodů se v posledních letech objevuje snaha o automatickou klasifikaci spánkových dat.

2 Polysomnografické měření

Studium spánkových fází má své počátky spojené s objevem EEG. V následujících letech bylo zjištěno, že se

v průběhu spánku mění i jiné fyziologické pochody, a že o spánkových fázích mohou vypovídat i jiné signály [1]. Zjistilo se například, že s hlubším spánkem klesá svalový tonus, během tzv. REM fáze dochází k rychlému pohybu očí a kolísá srdeční rytmus, což mělo za následek, že se začaly snímat současně s elektroencefalogramem i další signály. Vznikla tak polysomnografie (PSG), měření více parametrů během spánku [3].


2.1 Polysomnografie

Nejčastěji měřenými PSG signály v klinické praxi jsou: EEG, elektrookulogram (EOG) a elektromyogram (EMG) [2]. Není ovšem výjimkou, že se současně s nimi snímají i další signály, jako elektrokardiogram (EKG), krevní tlak, respirační či dokonce renální funkce [3].

EEG patří s EKG k nejznámějším a patrně také nejčastěji snímaným biosignálům a mimo diagnostiky spánkových poruch se užívá k diagnostice epilepsie, mozkových nádorů a dalších. Pro měření EEG se používají Ag/AgCl nebo zlaté elektrody o velikosti 10 mm, umístěné na kůži hlavy. Standardně se pro rozmístění elektrod užívá mezinárodní systém 10/20, signál se měří proti referenční elektrodě, která není pevně daná. Většinou se tedy měří proti elektrodám na ušních lalůčkách, případně proti elektrodě na čele (značené Fpz), výjimkou ovšem není měření rozdílu potenciálů mezi libovolnými elektrodami [3, 4]. Doporučené a alternativní svody podle manuálu AASM ukazují Obrázek 1.

Ačkoliv je EEG bezesporu nejdůležitějším signálem pro klasifikaci spánkových fází, další měřené parametry výrazně přispívají k přesnosti klasifikace. Jedním z takových signálů je snímání elektrické aktivity svalových buněk EMG. Podobně jako EEG se snímá pomocí elektrod z povrchu těla (invazivní metoda se u PSG nevyužívá), ty zachycují signál generovaný svalovými vlákny. Při měření PSG se obvykle používá měření svalového tonu pomocí submentální EMG (subEMG), kdy jsou elektrody umístěny zhruba 2 cm pod spodním okrajem dolní čelisti a asi 2 cm nalevo a napravo od pomyslné střední čáry. U subEMG jde především o měření svalového tonu, který se v průběhu noci snižuje až k minimu v průběhu tzv. REM fáze [3, 4].

Posledním typem signálu, použitým pro klasifikaci, je



Obrázek 1: Doporučené (A) a alternativní (B) svody EEG pro spánkové studie podle AASM [3].

EOG. Spolu s EEG a EMG tvoří nejčastěji používanou trojici signálů, používaných ke klasifikaci spánkových fází. Oko člověka můžeme považovat za dipól s kladnou rohovkou proti záporné sítnici. EOG se používá k registraci elektrických klidových očních potenciálů mezi předním a zadním pólem oka. Umístění elektrod se pak liší, obvykle jsou umístěny nasálně a temporálně v těsné blízkosti oka, referenční elektroda je obvykle na ušním lalůčku. Pro měření se používají Ag/AgCl elektrody o malých rozměrech, signál pak nabývá hodnoty stovek mikrovoltů až milivoltů [3, 4].

2.2 Spánkové fáze

Spánek se podle prvního manuálu R&K dělí na 6 fází - bdění (W), 4 fáze spánku (S1-S4) a fázi REM. Mimo jiné také tento manuál doporučuje spánek klasifikovat po 30s úsecích (epochách), kdy každému úseku je přiřazena hodnota (obvykle číselná) reprezentující jednu z šesti fází. Výsledný záznam se pak nazývá hypnogram [5]. Na dalších 40 let byl tento manuál standardem pro vizuální klasifikaci PSG dat. Na přelomu tisíciletí se však začala objevovat snaha modernizovat tento manuál, především z důvodu rozvíjejících se počítačových technologií a možnosti využít tyto technologie pro automatickou klasifikaci dat [6]. Odpovědí na tyto snahy byl manuál vydaný AASM v roce 2007. Ten spánek dělí do pěti fází podle jasně definovaných rozhodovacích pravidel, dále obsahuje doporučení pro měřicí přístroje a pro zpracování signálů [4].

Redukce počtu spánkových fází byla zapříčiněna především selháváním automatických klasifikačních metod na rozlišení fází S3 a S4 [6]. Z původních šesti tedy momentálně rozlišujeme pět spánkových fází [4]:

- Fáze Wake (W), stav bdělosti a plného uvědomění si okolí, je typická přítomností alfa rytmu, proměnlivou úrovní subEMG a možnou přítomností rychlých očních pohybů.
- Fáze Non-REM 1 (N1) je přechodem mezi bděním a spánkem, její trvání je obvykle 1—5 minut a jsou

pro ni typické pomalé pohyby očí s délkou trvání nad 0,5s a EEG signál s nízkou úrovní a frekvencí 4—7 Hz.

- Fáze Non-REM 2 (N2) představuje základ spánku a tvoří 45—55 % jeho trvání, typickým jevem pro tuto fázi jsou tzv. K-komplexy a spánková vřetena (krátké úseky o frekvenci 14-16Hz), EOG obvykle nevykazuje žádné oční pohyby.
- Fáze Non-REM 3 (N3) je fází hlubokého spánku a vznikla spojením fází S3 a S4, pro tuto fázi je typický signál EEG o nízké úrovni a frekvenci 0,5—2 Hz, přítomnost těchto pomalých vln je rozhodujícím faktorem pro klasifikaci fáze N3.
- Fáze REM (z anglického Rapid Eye Movement) je fází spánku, při které se nám zdají sny, tvoří obvykle 20—25 % jeho trvání, typickým jevem jsou nízké hodnoty subEMG a především přítomnost rychlých očních pohybů na záznamech EOG.

2.3 Zpracování naměřených dat

Prvním krokem před klasifikací dat je jejich filtrace, majících za úkol odstranění nežádoucích složek signálu. Těmito složkami bývá nejčastěji kolísání nulové izoliny (drift), způsobené dechovými pohyby či elektrochemickými ději mezi kůží a elektrodou a rušení způsobené elektrickou sítí [8].

Při zpracování EEG signálu pro klasifikaci spánkových fází nás zajímá především spektrální složení signálu. To totiž pro tyto potřeby mnohem lépe vystihuje aktivitu mozku než časová oblast signálu. Frekvence EEG se dělí na několik pásem (rytmů): delta (0—14 Hz), theta (4—8 Hz), alfa (8—13 Hz) a beta (více než 13 Hz). Horní frekvence beta pásma se v různé literatuře liší, obvykle se udávají hodnoty do 30 Hz, případně 35 Hz [1, 3, 4].

2.4 Umělé neuronové sítě

Jednou z klasifikačních metod, jež lze použít při skórování spánkových dat jsou umělé neuronové sítě. Podobně jako u biologických neuronových sítí je základní jednotkou umělé neuronové sítě jeden neuron - procesní prvek s více vstupy a jedním výstupem. Neuron je charakterizován vektorem vah, váhujícím vstupy neuronu, prahem a zvolenou funkcí, tzv. charakteristikou neuronu. Jeden neuron se dvěma vstupy funguje jako klasifikátor tak, že přiřadí dvojici vstupních hodnot do jednoho ze dvou prostorů v rovině, rozdělené přímkou. Rovnice této přímky je dána nastavením vah a prahu neuronu. Pro rozdělení prostoru složitějšími křivkami je nutné neurony spojovat do složitějších struktur - sítí. Důležitou vlastností sítě je schopnost učení, kdy jsou sítí předložena učební data a výsledek klasifikace je porovnán s očekávaným výstupem. V závislosti na velikosti odchylky jsou upraveny váhy neuronů a proces se

opakuje do doby, kdy síť dosáhne přijatelné chyby. Existuje více druhů učebních algoritmů, lišících se náročností výpočtu a vhodností použité pro různé typy dat [8].

2.5 Alternativní přístupy ke klasifikaci spánkových dat

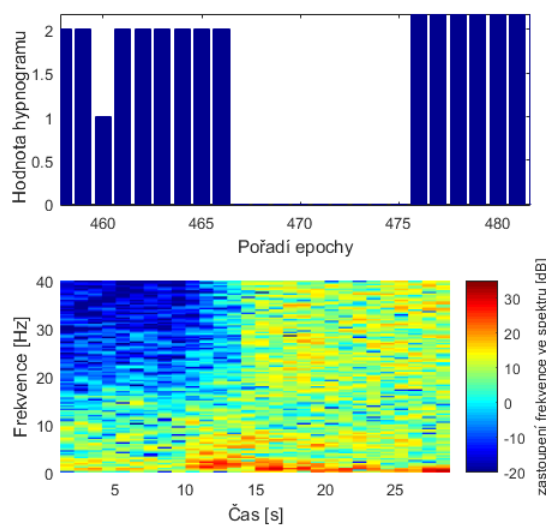
Signály lze rovněž vizualizovat v časově-frekvenční oblasti, abychom získali představu o vývoji spektra v čase. Signál o dané délce se rozdělí na menší, navazující nebo i částečně se překrývající úseky, ze kterých je vypočteno spektrum pomocí Fourierovy transformace (FT). Dílčí spektra jsou pak vykreslena v grafu - spektrogramu. V závislosti na délce zvoleného dílčího úseku dává spektrogram informace s lepším časovým nebo frekvenčním rozlišením [8].

Obrázek 2 ukazuje spektrogram (délka okna FT 3 s, překryv okna 2s) jednoho 30s úseku EEG, vyhodnoceného lidským expertem jako fáze W. V horní části obrázku je zobrazen úsek hypnogramu, epocha zobrazená spektrogramem odpovídá 467. skórovanému úseku a má hodnotu 0. Vzhledem k tomu, že se ve většině skórovaných epochy vyskytují vyšší frekvence, odpovídající alfa a beta rytmu EEG, byla epocha podle manuálu AASM vyhodnocena jako fáze bdění [4]. Ze spektrogramu lze ale vyčíst, že během prvních několika sekund se v EEG vyskytovaly převážně frekvence do 10 Hz, což odpovídá některé z fází hlubšího spánku. Tento předpoklad ještě podporuje fakt, že zobrazené fázi W předchází fáze vyhodnocená jako N2. Ze spektrogramu lze tedy usuzovat, že ke změně fáze z N2 na W došlo až zhruba po 10 sekundách úseku, který je ale podle současného standardu vyhodnocen celý jako W. V dnešní době se objevují studie, jejichž snahou je skórování PSG dat s vyšším časovým rozlišením [7]. Přestože není z časových důvodů možné, aby lidský expert vyhodnocoval data s vyšším časovým rozlišením než je daný standard 30 s, s využitím počítačové klasifikace by bylo možné zvýšit časové rozlišení hypnogramu na jednotky sekund.

3 Zpracování dat


Použitá PSG data pochází ze spánkové laboratoře Fakultní nemocnice u svaté Anny v Brně. Data byla naměřena již dříve, při studii RELIEF. Jedná se o studii, týkající se léčby pacientů s farmakoresistentní hypertenzí metodou ablace renálního sympatiku. Celkově bylo k dispozici 10 záznamů, každý z těchto záznamů obsahuje 20–22 naměřených signálů, mimo EEG, EOG a subEMG taky snímání dechu pomocí hrudního pásu a termočlátku, EKG záznam, poziční senzor, snímač chrápaní či oxymetr. Data již byla vyhodnocena manuálně lidským expertem, jednotlivým 30s úsekům byly přiřazeny hodnoty hypnogramu od 0 do 9 (0-W, 1-N1, 2-N2, 3-N3, 5-REM, 9-neklasifikováno).

Pro klasifikaci bylo použito šest signálů, jejich výběr byl založen na doporučení AASM - 3 svody EEG (svody Fz-Cz, Cz-Oz a C3M2), 2 svody EOG a subEMG, s těmito signály bylo pracováno podle schématu na Obrázku 3. Všechny signály byly vzorkovány na frekvenci 256 Hz a již byly z nemocnice předzpracovány filtrem typu horní propust



Obrázek 2: Ukázka úseku hypnogramu (nahore, hodnoty hypnogramu W=0, N1=1, N2=2) a spektrogramu signálu EEG (dole), odpovídajícímu 467. skórovanému úseku.

s mezní frekvencí 0,3 Hz pro odstranění driftu, dále pásmovou zádrží 50 Hz pro odstranění síťového rušení a dolní propustí s mezní frekvencí 70 Hz (100 Hz u EMG) pro odstranění nežádoucích vyšších spektrálních složek.



Obrázek 3: Schéma postupu při zpracování a klasifikaci dat.


Jelikož použitá data pocházela od nemocných pacientů, nebylo možné použít všechny dostupné záznamy z důvodu nedostatečného počtu některých spánkových fází (především REM). Tabulka 1 ukazuje přehled počtu jednotlivých spánkových fází u pěti pacientů, od nichž byla data použita. Vyhodnocení spánkových fází bylo provedeno lidským expertem.

Tabulka 1: Přehled počtu spánkových fází u pacientů 1-5

	W	N1	N2	N3	R
Pacient 1	212	168	278	103	115
Pacient 2	120	129	331	162	92
Pacient 3	256	72	308	81	135
Pacient 4	134	50	431	86	121
Pacient 5	117	166	320	206	68

Obrázek 4 ukazuje příklad předzpracovaných signálů EEG (svod FzCz), EOG (levého oka) a subEMG, signály


odpovídají jednomu 30s náhodně vybranému úseku, který odpovídá podle lidského experta fázi N2.



Obrázek 4: Ukázka 30s úseku použitého pro klasifikaci.

3.1 Vytvoření klasifikačních příznaků


Práce se signály EEG probíhala v časově-frekvenční oblasti, neboť u tohoto typu signálu nás zajímá především přítomnost jednotlivých EEG rytmů [4, 3]. Jelikož cílem je zvýšení časového rozlišení, byl nejprve vypočítán z každého 30s úseku spektrogram. Velikost okna FFT byla zvolena 3s (768 vzorků) s překryvem 2s, čímž bylo dosaženo časového rozlišení 1s. Jednotlivá spektra ve spektrogramu poté sloužila pro výpočet relativního zastoupení EEG rytmů jako podílu sumy spektrálních čar odpovídajících danému rytmu a sumy všech spektrálních čar. Ukázku získaných klasifikačních příznaků z jednoho svodu EEG pro jednu epochu (vyhodnocenou lékařem jako W) ukazuje Obrázek 5.



Obrázek 5: Ukázka příznaků vypočtených ze signálu EEG.

Signály EMG a EOG byly oba zpracovány stejným způsobem v časové oblasti. Jelikož se u obou signálů v průběhu spánku mění především hodnota maximální výchylky [4, 7], bylo na tyto signály aplikováno posuvné okno délky 3s

s překryvem 2s (tedy stejné časové rozlišení 1s jako u signálu EEG) a v tomto okně byla vypočítána hodnota maximální výchylky jako rozdíl nejnižší a nejvyšší hodnoty. Ukázku vypočtených parametrů z jedné náhodné epochy N1 a porovnání s původním signálem ukazuje Obrázek 6.



Obrázek 6: Ukázka signálů EOG (a), EMG (b) a příznaků vypočtených z EOG (c) a EMG (d).

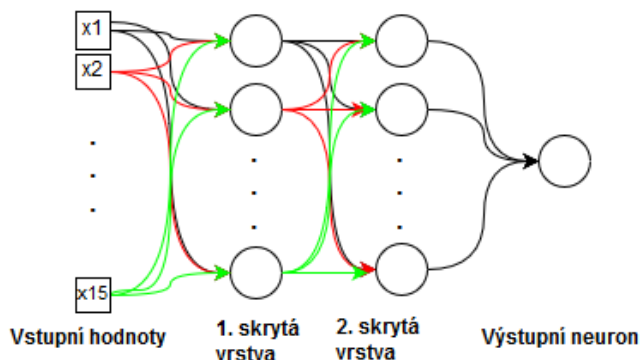
Tímto způsobem bylo vytvořeno 15 klasifikačních příznaků - sada 4 příznaků pro každý ze tří svodů EEG, 2 příznaky pro jednotlivé kanály EOG a jeden pro subEMG.

3.2 Klasifikace

Samotná klasifikace probíhala pomocí neuronových sítí vytvořených v programovém prostředí MATLAB (verze 2015b). Použity byly jednoduché dopředné sítě s jedním výstupním neuronem s lineární aktivační funkcí, očekávané výstupní hodnoty sítě pak byly pro jednotlivé fáze: W-1, N1-2, N2-3, N3-4, REM-5. Síť má dvě skryté vrstvy s proměnlivým počtem neuronů v každé z nich, v první vrstvě bylo použito 13–23 neuronů, v druhé 5–9, testována byla každá kombinace. Aktivační funkce skrytých neuronů je sigmoidální. Schéma použité neuronové sítě ukazuje Obrázek 7.

Při učení neuronové sítě byl nastaven maximální počet učebních iterací 500, krok učení 0,01 a cílová hodnota kvadratické chyby (MSE) 0,05. Pro srovnání byly použity tři metody učení: Levenberg-Martquardt (LM), což je obvykle nejrychlejší algoritmus, BFGS quasi-Newtonova metoda zpětné propagace (BFG), další z rychlých algoritmů, jehož náročnost ale narůstá kvadraticky s počtem proměnných a metoda gradientního sestupu (GDX), nejpomalejší z použitých učebních algoritmů, rychlost učení je adaptivní v závislosti na výkonnosti sítě v předchozí epoše (vyjádřené hodnotou MSE).

Velikost vstupní množiny dat se lišila v závislosti na počtu klasifikovaných fází. Každá spánková fáze byla zastoupena 40 epochami od každého z pěti pacientů, v každé



Obrázek 7: Schéma použité neuronové sítě.

30s epoše bylo vypočteno 28 sad příznaků (2 sekundy v každé epoše chybí kvůli délce okna), celkově tedy 5600 sad příznaků pro každou spánkovou fázi (28 000 sad celkem), vyšší počet nebyl vzhledem k průběhu spánku pacientů možný. 80 % dat bylo použito pro trénování sítě, zbylých 20 % pak pro testování sítě.

4 Výsledky klasifikace

Spánková data byla klasifikována ve třech variantách. Nejjednodušší variantou je rozlišování pouze fází W a N3. Vzhledem k tomu, signály EEG mají během těchto fází naprosto odlišné spektrum a rovněž signály EOG a EMG dosahují odlišných úrovní [4], neměla by mít neuronová síť problém tyto fáze rozlišit. Dále je přidána fáze REM, která je v mnohých ohledech podobná N3 fázi [4], a tak lze očekávat záměny. Nejnižší úspěšnost klasifikace se pak dá očekávat při rozlišování všech fází, především díky podobnosti fází N1 a N2, N1 a W nebo N1 a REM.

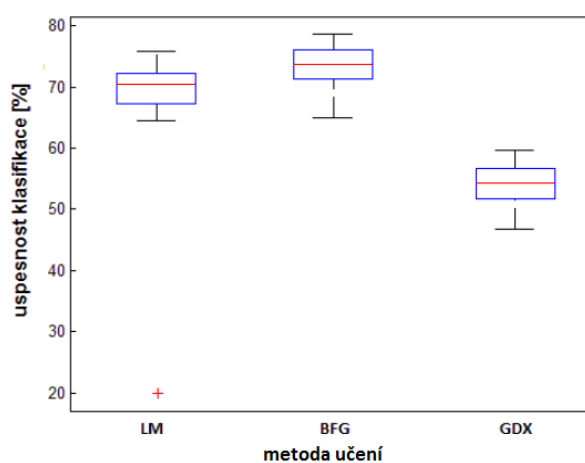
Výsledek každé klasifikace je možné popsat maticí záměn. Příkladem je Tabulka 2, která představuje matici záměn neuronové sítě LM-16-7, kde LM označuje metodu učení a číselné hodnoty odpovídají počtu neuronů v první a druhé skryté vrstvě. Jednotlivé sloupce představují očekávané hodnoty spánkové fáze tak, jak byly vyhodnoceny lidským expertem, řádky odpovídají výstupním hodnotám neuronové sítě. V tomto případě bylo 85,5 % fází W, 86,2 % fází N3 a 76,8 % REM fází vyhodnoceno shodně s lidským expertem. Horších výsledků dosahovala shoda s lidským expertem u fází N1 a N2 - pouze 60 % a 61 %. Mezi těmito dvěma fázemi docházelo často k záměně. Celková úspěšnost klasifikace pak byla určena jako průměr diagonálních hodnot, které odpovídají počtu fází určených shodně lidským expertem a neuronovou sítí.

Po vytvoření matice záměn pro každou konfiguraci sítě byla vybrána u každé učební metody nejúspěšnější kombinace počtu neuronů a pro tuto kombinaci pak byla síť 20 krát znovu trénována a testována, aby byl omezen vliv náhodného počátečního nastavení vah a prahů neuronové sítě. Výsledné hodnoty úspěšnosti pak byly vyneseny do krabicového grafu, jako ukazuje Obrázek 8. Zde je zaznačen

Tabulka 2: Ukázka matice záměn pro konfiguraci sítě LM-16-7.

	W	N1	N2	N3	R	
W	957	152	21	0	48	81%
N1	124	667	156	8	140	60%
N2	19	206	663	144	78	59%
N3	1	11	163	954	7	83%
R	18	76	83	1	903	83%
	85%	60%	61%	86%	76%	74%

výsledek opakovaného trénování a testování sítí s konfiguracemi LM-18-5, BFG-18-5 a GDX-19-6. NA první pohled jsou sítě, trénované metodami LM a BFG, úspěšnější, než síť využívající gradientní metodu.



Obrázek 8: Výsledná úspěšnost opakovaných trénování a testování sítí.

Výsledky všech klasifikací shrnuje Tabulka 3. V případě klasifikace fází W a N3 bylo za použití neuronových sítí LM-20-7 a BFG-7-20 dosaženo 100 % shody s lidským expertem, v případě sítě GDX-6-19 hodnota úspěšnosti dosahovala téměř hodnoty 100 %. V případě, že byla pro klasifikaci přidána fáze REM, dosáhla nejvyšší úspěšnosti síť LM-18-7 s hodnotou téměř 100 %, síť BFG-16-7 a GDX-17-6 dosáhly hodnot přes 90 %. Při klasifikaci všech pěti fází pak bylo dosaženo nejvyšší shody s lidským expertem při použití sítě BFG-18-5, naopak jako nevhodná se ukázala síť trénovaná metodou gradientního sestupu.

Tabulka 3: Hodnoty shody s lidským expertem pro různé nastavení sítí.


Klasifikované fáze	Úspěšnost [%]		
	LM	BFG	GDX
W,N3	100	100	97-100
W, N3, REM	99-100	97-99	92-95
W, N1-3, REM	68-72	72-76	50-55

Jelikož byly do klasifikace zahrnuty i ty epochy, během kterých může docházet ke změně spánkové fáze, může být

Tabulka 4: Srovnání různých metod klasifikace spánkových fází

Rok vydání	Autor	Metoda klasifikace	Klasifikované fáze	Úspěšnost
2012	Álvarez-Estévez [7]	Expertní systém	W, N1-3, R	84%
2008	Ebrahimi [9]	Neuronové sítě	W, S1+R, S2, SWS	88-98%
2011	Fraïwan [10]	Náhodný les	W, N1-3, R	83%
1999	Oropesa [11]	Neuronové sítě	W, S1, S2, R	70-80%
2011	Ronzhina [2]	Neuronové sítě	W, S1-4, R	64-96%

výsledná shoda s lidským expertem snížena i těmito fázemi. Jako příklad může sloužit už jednou uváděná 467. epocha pacienta č.6. Tato epocha byla překlasifikována pomocí neuronové sítě BFG-18-5 a následně byl vytvořen nový hypnogram s vyšším časovým rozlišením pro tuto jednu epochu na Obrázku 9. Na tomto obrázku vidíme, že prvních 11 sekund bylo klasifikováno jako spánek s hodnotou hypnogramu 2 (fáze N2) nebo 5 (fáze REM). Těchto 11 sekund se tedy neshoduje s lidským expertem, přesto však nelze říct, že by se jednalo o chybnou klasifikaci. Zbytek epochy pak byl shodně klasifikován jako fáze W (hodnota hypnogramu 0).



Obrázek 9: Nový hypnogram s vyšším časovým rozlišením.

5 Diskuze

Článek se zabýval klasifikací spánkových fází s vyšším časovým rozlišením za použití umělých neuronových sítí. Umělé neuronové sítě lze považovat, při použití uvedených klasifikačních příznaků, za naprosto vyhovující pro klasifikaci spánkových fází W, N3 a REM. Bez ohledu na konkrétní nastavení sítě a použitou učební metodu přesahovaly hodnoty shody s lidským expertem 90 %.

Při klasifikaci všech spánkových fází již dosahoval klasifikátor nižších hodnot a na první pohled by se mohlo zdát, že hodnoty úspěšnosti 72–76 % nejsou dostačující. Nutno však brát v potaz fakt, že hodnota shody dvou lidských expertů běžně dosahuje 80–85 % [2]. Dále je třeba uvažovat přítomnost epoch, během kterých může docházet k přechodu spánkových fází nebo krátkodobým změnám, které lidský expert neklasifikoval. Pokud se takové epochy objeví v testovacích datech, může být výsledná shoda s lidským expertem rovněž snížena.

Pro srovnání dosažených výsledků uvádí Tabulka 4 výsledky jiných studií, které používaly neuronové sítě a ve dvou případech jiné klasifikační metody. Zde se úspěšnost klasifikace pohybuje v hodnotách kolem 80–90 %, tedy vyšších než při postupu použitým v tomto článku. Tento postup má značné mezery především v určení fází N1 a N2, které jsou pro klasifikaci nejkomplicovanější. Zde se tedy otvírá možnost pro další studium problematiky a hledání vhodnějších klasifikačních příznaků. Jako jednu z možností pro další výzkum lze uvést detekci K-komplexů a spánkových vřeten, které jsou typické pro fázi N2 [4]. Dále se nabízí možnost podrobnějšího předzpracování signálů kvůli odstranění případných artefaktů, které mohou u tak vysokého časového rozlišení ovlivnit klasifikaci. Rovněž by bylo možné vyzkoušet použití jiné klasifikační metody než umělých neuronových sítí.

6 Závěr

Tento článek se zabývá popisem klasifikací PSG dat s vyšším časovým rozlišením hypnogramu. Konvenční 30s časový úsek pro klasifikaci je snížen na 1 s. Takový přístup by mohl pomoci při diagnostice chorob spojených se spánkem a rovněž by mohl pomoci pochopit změny probíhající v lidském těle během spánku. Dosažené výsledky dosahují srovnatelných hodnot s jinými studii, úspěšnost klasifikace 72–76 % ale stále není dostatečná pro použití v klinické praxi. Nabízí se tak prostor pro další studium, především v oblasti extrakce vhodných klasifikačních příznaků a výběru klasifikačních metod pro klasifikaci spánkových fází.

Literatura

- [1] ŠUŠMÁKOVÁ, K.: *Human sleep and sleep EEG*. In *Measurement Science Review*, 2004, roč. 4, č 2, s. 59-74. ISSN 1335-8871.
- [2] RONZHINA, Marina, Oto JANOUŠEK, Jana KO-LÁŘOVÁ, Marie NOVÁKOVÁ, Petr HONZÍK a Ivo PROVAZNÍK. *Sleep scoring using artificial neural networks*. 2012. *Sleep Medicine Reviews* [online]. 16(3), 251-263. DOI: 10.1016/j.smrv.2011.06.003. ISSN 10870792
- [3] VAUGHN, Bradley V. a Peterson GIALLANZA. *Technical Review of Polysomnography*. Chest [online]. 2008. Elsevier Inc, 134(6), 1310-1319. DOI: 10.1378/chest.08-0812. ISSN 00123692..

- [4] *IBER, Conrad. The AASM manual for the scoring of sleep and associated events: rules, terminology and technical specifications.* 2007. Westchester, IL: American Academy of Sleep Medicine, 57 s.
- [5] *RECHSCHAFFEN, Allan a Anthony KALES (eds.). A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects.* 1968. Washington D.C.: Public Health Service, U.S. Government Printing Office, 58 s.
- [6] *HORI, Tadao, Yoshio SUGITA, Einosuke KOGA, et al. Proposed supplements and amendments to ' A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects ', the Rechtschaffen & Kales (1968) standard.* 2001. Psychiatry and Clinical Neurosciences [online]. Melbourne, Australia: Blackwell Science Pty, 55(3), 305-310. DOI: 10.1046/j.1440-1819.2001.00810.x. ISSN 13231316.
- [7] *ÁLVAREZ-ESTÉVEZ, Diego, José M. FERNÁNDEZ-PASTORIZA, Elena HERNÁNDEZ-PEREIRA a Vicente MORET-BONILLO. A method for the automatic analysis of the sleep macrostructure in continuum.* 2013. Expert Systems with Applications [online]. 40(5), 1796-1803. DOI: 10.1016/j.eswa.2012.09.022. ISSN 09574174.
- [8] *JAN, Jiří. Číslicová filtrace, analýza a restaurace signálů.* 2002. 2. upr. a rozš. vyd. Brno: VUTUM. ISBN 8021415584
- [9] *EBRAHIMI, Farideh, Mohammad MIKAEILI, Edson ESTRADA a Homer NAZERAN. Automatic sleep stage classification based on EEG signals by using neural networks and wavelet packet coefficients.* 2008. 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society [online]. IEEE, s. 1151-1154. DOI: 10.1109/IEMBS.2008.4649365. ISBN 978-1-4244-1814-5
- [10] *FRAIWAN, Luay, Khaldon LWEEZY, Natheer KHASAWNEH, Heinrich WENZ a Hartmut DICKHAUS. Automated sleep stage identification system based on time-frequency analysis of a single EEG channel and random forest classifier.* 2012. Computer Methods and Programs in Biomedicine [online]. Elsevier Ireland Ltd, 108(1), 10-19. DOI: 10.1016/j.cmpb.2011.11.005. ISSN 01692607.
- [11] *OROPESA, Edgar a Marc JOBERT. Sleep stage classification using Wavelet transform and neural network.* 1991. International Computer Science Institute Technical Report