

PSG-BASED CLASSIFICATION OF SLEEP PHASES

Martin Králík

Master Degree Programme (2), FEEC BUT

E-mail: xkrali18@stud.feec.vutbr.cz

Supervised by: Marina Ronzhina

E-mail: ronzhina@feec.vutbr.cz

Abstract: This work is focused on classification of sleep phases using artificial neural network. The unconventional approach was used for calculation of classification features using polysomnographic data (PSG) of real patients. This approach allows to increase the time resolution of the analysis and, thus, to achieve more accurate results of classification.

Keywords: polysomnography, sleep scoring, classification features, neural networks

1. ÚVOD


Výzkum spánku v minulém století zaznamenal velký rozvoj, za posledních 50 let jsou však používány stále stejné postupy pro klasifikaci spánkových fází, které byly v roce 2006 jen mírně upraveny Americkou akademií spánkové medicíny (AASM). Konvenční skórování spánku je prováděno v třicetisekundových intervalech. Není proto divu, že se v poslední době objevují pokusy o modernizaci, jako je například zvýšení časového rozlišení výsledného hypnogramu [1], kterým se zabývá tato práce.

2. KLASIFIKACE SPÁNKOVÝCH FÁZÍ

Data použitá v tomto článku pochází ze spánkové laboratoře Fakultní nemocnice u svaté Anny v Brně. Tato data byla naměřena již dříve, v rámci studie RELIEF, která se týkala léčby pacientů s farmakorezistentní hypertenzí metodou ablace renálního sympatiku. Jedná se o PSG data od asi třiceti pacientů, každý záznam obsahuje 20 až 22 signálů, včetně již manuálně vyhodnoceného hypnogramu, jež byl použit jako referenční při učení a testování neuronových sítí. Data byla dodána ve formátu .MAT, je však známo, že byla původně uložena ve formátu .EDF, předzpracována filtry a konvertována. Všechny použité signály jsou vzorkovány na frekvenci 256Hz. [2].

2.1. VYTVOŘENÍ KLASIFIKAČNÍCH PŘÍZNAKŮ

Při klasifikaci bylo pracováno se signály, které doporučuje i AASM, tedy se signálem EMG-sub měřeným na bradě, dále se dvěma svody EOG z levého a pravého oka a dvěma svody EEG – C4M1 a C3M2. Při konvenční klasifikaci jsou signály EMG a EOG zpracovávány obvykle v časové oblasti, signál EMG pak poskytuje užitečné informace jak v časové (detekce graofelementů), tak především ve frekvenční oblasti [3]. Před samotnou klasifikací byly z výše uvedených signálů vypočteny parametry, sloužící jako klasifikační příznaky. Signály EOG1, EOG2 a EMG jsou reprezentovány hodnotou maximální výchylky, spočítanou v okně velikost 3s (768 vzorků) v překryvem 2s (parametry aEMG, aEOG1, aEOG2), neboť nás zajímá především velikost změny signálu. U signálů EEG byly vytvořeny spektrogramy (parametry okna stejné jako v předchozím případě) a z nich pak pro každý svod 4 parametry, reprezentující relativní zastoupení jednotlivých spánkových rytmů: $\delta = 0-4\text{Hz}$, $\theta = 4-8\text{Hz}$, $\alpha = 8-13\text{Hz}$, $\beta = 13-30\text{Hz}$ (parametry pDelta1, pTheta1, pAlfa1, pBeta1 respektive pDelta2, pTheta2, pAlfa2, pBeta2 pro druhý svod EEG). Ukázkou relativního zastoupení jednotlivých rytmů ve spektru EEG v rámci jednoho kratšího úseku (odpovídá 31. fázi Wake) vidíme na Obrázku 1.




Obrázek 1: Ukázka signálů spánkových rytmtů

2.2. KLASIFIKACE FÁZÍ WAKE A N3

Přestože se práce pokouší využívat alternativních postupů při klasifikaci spánkových fází, je spánek dělen podle doporučení AASM na fázi bdění (W), tři fáze různě hlubokého spánku (N1-N3) a fázi, kdy se zdají sny (REM). Nejjednodušší klasifikací je dělení spánku na bdění (W) a hluboký spánek (N3), neboť lze očekávat, že se tyto fáze nejvíce liší.

Samotná klasifikace proběhla pomocí neuronových sítí, vytvořených v programovém prostředí MATLAB (verze 2009b). Jedná se o jednoduchou dopřednou síť s jedním výstupním neuronem s lineární aktivační funkcí. Síť má dvě skryté vrstvy s proměnlivým počtem neuronů v každé z nich, aktivační funkce skrytých neuronů je sigmoidální. Při učení byla užita metoda gradientního sestupu, cílová hodnota kvadratické chyby 0.01, počet učebních epoch 300 a krok učení 0.01. Schéma neuronové sítě ukazuje Obrázek 2.



Obrázek 2: Schéma neuronové sítě

Jako učební data byly použity výše uvedené parametry z 280 sekund fáze W a 280 sekund fáze N3. Učební data byla vybrána tak, aby plně reprezentovala danou fázi, neboli aby neobsahovala přechody mezi fázemi. Jako testovací data byla vytvořena matice 11x112, obsahující rovnoměrné zastoupení W a N3 z jiných období spánku. Výstupní vektor byl kódován hodnotami 0 pro W fázi a 1 pro N3. Bylo provedeno testování neuronové sítě s 13-20 neurony v první a 3-6 neurony ve druhé skryté vrstvě. Pro každou kombinaci byla úspěšnost testovací množiny 100%, odlišná nebyla ani rychlosti učení různě rozsáhlých neuronových sítí. Lze tak říci, že pro klasifikaci dvou naprosto odlišných spánkových fází, jako je W a N3, je dostačující neuronová síť s 13 a 3 neurony ve skrytých vrstvách, využívající 11 navržených parametrů.

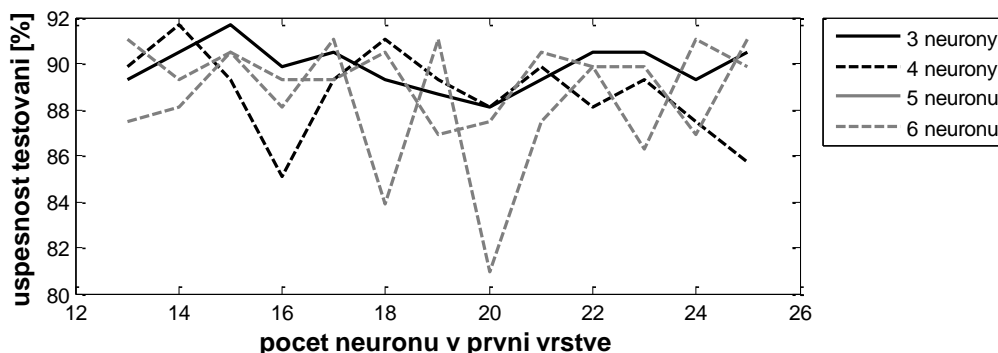
2.3. KLASIFIKACE FÁZÍ WAKE, N3 A REM

V druhé části byla do klasifikace zahrnuta další spánková fáze – REM. Předpokladem bylo, že se zhorší přesnost klasifikace, neboť REM fáze má společné znaky se zbylými fázemi. Proti fázi N3 lze očekávat vyšší mozkovou aktivitu, stejně nízký by však měl být svalový tonus. Stejně jako u fáze bdění očekáváme u REM pohyby očí [2].

Pro klasifikaci byla použita neuronová síť o téměř stejné struktuře, jako v předchozím případě. Na rozdíl od ní ale byl zde testován vyšší počet neuronů v první vrstvě a byl použit vyšší počet učeb-

ních epoch. Pro učení byla vytvořena matice ze tří matic 11x280, jejich výběr probíhal stejně jako v případě klasifikace dvou fází – jsou tedy vyloučeny okrajové části spánkových úseků. Testovací množina pak obsahuje tři matice 11x56 s rovnoměrným zastoupením všech tří fází, výstupní vektor kódován hodnotami 1 až 3 pro fáze W, N3 a REM.

Při žádném z uvedených nastavení neuronové sítě nebylo dosaženo cílové hodnoty kvadratické chyby 0.01 a učení každé sítě tak končilo po 500 epochách. Hodnota 500 epoch byla zvolena především proto, aby nedocházelo k nežádoucímu přeučení sítě. Otestováno bylo celkem 52 různých nastavení skrytých vrstev sítě, počet neuronů první vrstvy se měnil v rozmezí 13-25, u druhé vrstvy stejně jako v předchozím případě 3-6. Výsledné úspěšnosti testování pro jednotlivé kombinace zobrazuje Obrázek 3.



Obrázek 3: Závislost úspěšnosti klasifikace neuronové sítě na počtu neuronů

Z grafu lze vyčíst, že nejlepší výsledky dosahovaly jednodušší sítě se třemi a čtyřmi neurony v druhé vrstvě a 15 resp. 14 neurony ve vrstvě první. Při bližším pohledu na výsledky testování sítě 14-4 zjistíme, že zatímco všech 56 W a N3 fází bylo klasifikováno správně, u REM fáze byla úspěšná klasifikace pouze u 42 případů. Tento fakt je důsledkem již zmiňované podobnosti REM fáze se zbylými dvěma fázemi.

3. ZÁVĚR

Z výsledků práce lze usuzovat, že klasifikace spánkových fází s vyšším časovým rozlišením je proveditelná a neuronové sítě jsou vhodným prostředkem pro takovou klasifikaci. Při dělení na bdělost/hluboký spánek bylo dosaženo 100% přesnosti detekce, po přidání fáze REM se úspěšnost snížila na zhruba 92%. Lze tedy říci, že klasifikace spánku „in continuum“ je reálná a mohla by po dalším výzkumu v některých případech nahradit konvenční metodu, kde se hypnogram vytváří pro 30s úseky PSG záznamů.

REFERENCE

- [1] ÁLVAREZ-ESTÉVEZ, Diego, José M. FERNÁNDEZ-PASTORIZA, Elena HERNÁNDEZ-PEREIRA a Vicente MORET-BONILLO. A method for the automatic analysis of the sleep macrostructure in continuum. *Expert Systems with Applications* [online]. 2013, vol. 40, issue 5, s. 1796-1803 [cit. 2015-03-02]. DOI: 10.1016/j.eswa.2012.09.022
- [2] FAKULTNÍ NEMOCNICE U SV. ANNY. *Měření polysomnografických (PSG) signálů v rámci grantu „Význam spánkové apnoe v patofyziologii a léčbě fibrilace síní“: Manuál k měření* [.doc]. 23 s. [cit. 2015-01-03]. NS 100 98-4
- [3] IBER, Conrad. *The AASM manual for the scoring of sleep and associated events: rules, terminology and technical specifications*. Westchester, IL: American Academy of Sleep Medicine, c2007, 59 p.