

## Skórovanie spánkového stavu NREM2 pomocou detekcie K-komplexu

Gála Michal · Elektrotechnika, Medicína

07.02.2011



Článok sa zaoberá opisom metódy pre detekciu výskytu K-komplexu v spánkovom EEG. K-komplex je ostrá záporná vlna nasledovaná pomalšou pozitívnou vlnou. Výskyt opisovanej vlny je charakteristický pre spánkový stav NREM2. Správne skórovanie daného spánkového stavu je veľmi dôležité, pretože spánkový stav NREM2 tvorí 50 - 60% celkovej doby spánku. Zvyšné percentá sú tvorené spánkovými stavmi REM, NREM1, NREM3 a NREM4. Metóda detekcie K-komplexu je založená na použití zhlukovej analýzy a jednoduchej neurónovej siete.

### 1. Úvod

Počítačové predspracovanie a analýza biologických signálov má veľký význam pre skvalitňovanie výslednej diagnózy stanovenej lekárom. V prípade niekoľko hodinových signálov (celodenné EKG, spánkové EEG) vedie aj k nezanedbateľnej úspore času. Spánok sa delí na niekoľko spánkových štádií (stavov), z ktorých je možné niektoré detegovať relatívne dobre a niektoré nie. Prvú skupinu tvoria stavy NREM3 a NREM4, ktorých detekcia v rámci nášho algoritmu na detekciu spánkových stavov je vysoká (80%). Okrem už spomínaných stavov existujú aj stavy REM, NREM1 a NREM2, ktorých detekcia je omnoho komplikovanejšia.

Z tohto dôvodu sa snažíme vytvoriť postup pomocou, ktorého by bolo možné identifikovať tieto stavy. Článok sa zaoberá opisom metódy pre detekciu výskytu K-komplexu v spánkovom EEG, ktorý je charakteristický pre stav NREM2. Doplnením vyhľadávania spánkových vretienok, ktoré sú tiež charakteristické pre stav NREM2 bude možné pomocou tejto metódy presnejšie stanoviť či sa jedná o stav NREM2 alebo nie. K-komplex je ostrá záporná vlna nasledovaná pomalšou pozitívnou vlnou. Spánkové vretienko je vlna trvajúca minimálne 0,5 sekundy s frekvenciou 12-14Hz [1, 2, 3].



Obr. 1: Úsek signálu obsahujúci K-komplex a spánkové vretienko (charakteristické pre stav NREM2).

## 2. Použité metódy a algoritmy


Vyhľadávanie K-komplexov prebiehalo na 30 sekúnd trvajúcich úsekoch spánkového EEG. Teda niekoľkohodinový záznam (použité boli 8 hodinové záznamy) sa rozdelil na 30 sekundové úseky tzv. epochy, ktoré sa následne skórovali. EEG signál je nestacionárny a stochastický, pre jeho ďalšie spracovanie bolo potrebné vzniknuté epochy spracovať pomocou adaptívnej segmentácie a vytvoriť tak kvázi stacionárne úseky, ktoré sa ďalej analyzovali.

### 2.1 Segmentácia signálu

Ako je uvedené v kapitole 2, EEG signál je signál nestacionárny. Na vytvorenie kvázi stacionárnych úsekov - segmentov sa používa adaptívna segmentácia. Existuje viacero metód adaptívnej segmentácie:

- adaptívna segmentácia využívajúca jednoduchého testu na stanovenie hraníc segmentov
- adaptívna segmentácia metódou dvoch spojených okien
- adaptívna segmentácia využívajúca štandardnú odchýlku

Posledne zmieňovaná metóda je nová metóda segmentácie, ktorú sme navrhli na základe tzv. Hjorthových parametrov, pri ktorých sa využíva rozptyl, čo je vlastne štandardná odchýlka umocnená na druhú. Túto metódu sme použili aj pre tento prípad. Metóda sa ešte stále testuje a upravuje. Metóda je založená na poznatku, že signály s rovnakou amplitúdou a frekvenciou majú rovnakú štandardnú odchýlku.



Obr. 2: Aplikácia adaptívnej segmentácie využívajúcej štandardnú odchýlku na viackanálové EEG, červené čiary znázorňujú hranice segment.

Pri zmene (variabilite) či už amplitúdy alebo frekvencie sa mení aj štandardná odchýlka. Najpoužívanejšou mierou variability je rozptyl, ktorý sa rovná priemernému štvorcu odchýlky hodnoty od priemeru. Čím je rozptyl väčší, tým sa údaje viac odchyľujú od priemeru. Rozptyl sa vypočíta podľa vzorca:

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

kde  $n$  je počet vzoriek a  $\bar{x}$  je aritmetický priemer:

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

Dôsledkom nutného umocňovania je vypočítaná hodnota rozptylu v štvorcoch pôvodných jednotiek. Aby sa odstránil nežiaduci vplyv umocňovania, rozptyl sa odmocní, čím sa vypočíta štandardná odchýlka:

$$s = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

## 2.2 Extrakcia príznakov

Pre čo najlepší popis vytvorených EEG segmentov boli použité príznaky popisujúce časové a frekvenčné parametre adaptívnou segmentáciou vzniknutých segmentov [4].

- Variancia amplitúdy v segmente dĺžky L
- Rozdiel maximálnej pozitívnej a minimálnej negatívnej hodnoty amplitúdy v segmente
- Hodnoty amplitúdy signálu v delta, théta, alfa, beta1 a beta2 frekvenčných pásmach
- Maximálna hodnota prvej derivácie signálu v segmente (úmerná sklonu krivky grafoelementu) aproximovaná vzťahom
- Maximálna hodnota druhej derivácie signálu v segmente (úmerná špicatosti krivky)

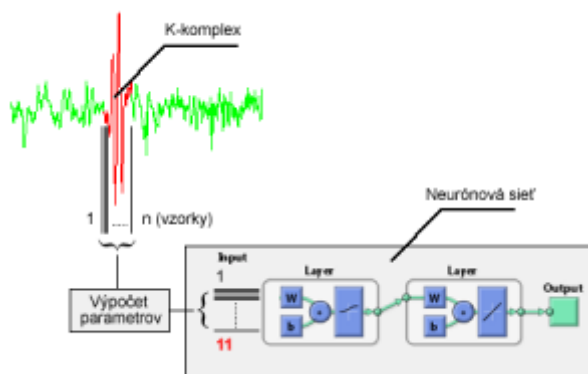
Ďalšiu skupinu parametrov tvoria tzv. Hjorthove parametre. Tieto parametre popisujú EEG signál v časovej oblasti. Prvý parameter predstavuje strednú hodnotu výkonu a reprezentuje tak aktivitu signálu, preto sa nazýva tento parameter ako „aktivita“. Druhý Hjorthov parameter sa nazýva „mobilita“ a reprezentuje odhad strednej frekvencie. Tretí Hjorthov parameter alebo tiež „komplexnosť“ predstavuje odhad šírky pásma.

## 2.3 Rozdelenie segmentov do tried

Získané popisy (v časovej aj frekvenčnej oblasti) segmentov boli použité na zatriedenie jednotlivých segmentov do tried - zhlukov pomocou zhlukovej analýzy. Zhluková analýza predstavuje dôležitý nástroj pre riešenie klasifikačných problémov. Cieľom zhlukovej analýzy je zaradiť vstupné objekty do jednotlivých skupín tak, že podobnosť medzi objektmi v rámci skupiny je veľmi veľká, na druhej strane je však podobnosť medzi objektmi rôznych skupín veľmi malá. Jednou z najjednoduchších metód spomedzi nehierarchických metód zhlukovej analýzy je metóda k-means [5, 9]. Táto metóda jednoduchým spôsobom klasifikuje vstupné dáta do vopred definovaného počtu zhlukov. V našom prípade boli použité 2 triedy.

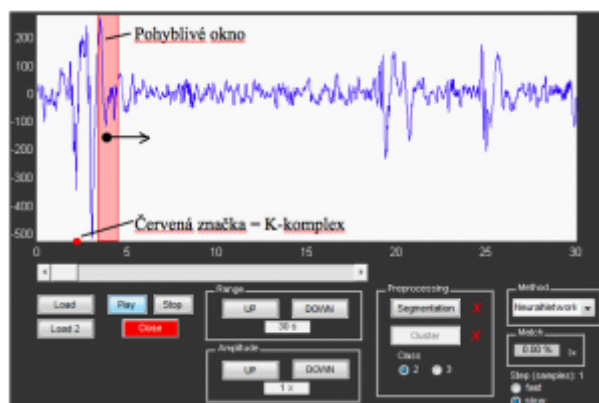
## 2.4 Vyhľadanie K-komplexu

V tomto kroku bolo najdôležitejšie najskôr za pomoci neurológa pootznačovať manuálne K-komplexy vyskytujúce sa v tréningovom signáli. Parametre (príznaky) týchto označených úsekov boli použité ako tréningová množina pre neurónovú sieť. Boli použité parametre popisujúce signál vo frekvenčnej a časovej oblasti. V tomto prípade môžu mať K-komplexy použité pre tréningovanie siete rôznu dĺžku. Počet vstupov siete bol 11 (signál popisuje 11 parametrov ako napr. maximálna hodnota amplitúdy, maximálna frekvencia, maximálna hodnota prvej, druhej derivácie, ...).



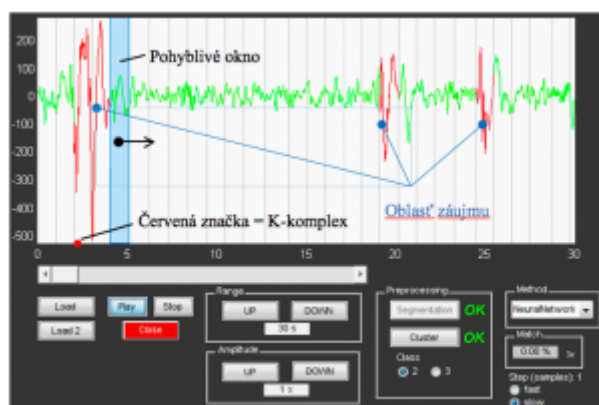
Obr. 3: Neurónová sieť využívajúca ako vstupy parametre signálu.

Pre vyhľadávanie boli zvolené dva postupy, prvý je zdĺhavejší, ale poskytuje celkové prehľadanie 30 sekundového úseku. Druhý postup je časovo menej náročný, no prehľadávajú sa len určité časti 30 sekúnd trvajúceho úseku spánkového EEG (je potrebná segmentácia a zhluková analýza). Oba postupy využívajú „okno“ pohybujúce sa po signáli. Časť signálu, ktorá je v danom momente obsiahnutá v okne sa použije ako vstup do neurónovej siete, ktorá následne vyhodnotí či daný úsek má črty K-komplexu.



Obr. 4: Prehľadávanie celého 30s úseku

Ak sieť vyhodnotí, že zhoda medzi aktuálnym a natrénovaným výstupom siete je väčšia ako 80%, systém to zaznamená a dané miesto v signáli označí bodkou ako miesto s K-komplexom. Parametre K-komplexu (obr. 1) sú iné ako parametre zvyšnej časti signálu tvoriaceho epochu. Z tohto dôvodu nie je potrebné prechádzať oknom po celom signáli, ale len po určitých častiach signálu. Signál je však potrebné najskôr predspracovať pomocou adaptívnej segmentácie, vypočítať parametre jednotlivých segmentov a rozdeliť ich pomocou zhlukovej analýzy do tried.



Obr. 5: Prehľadávanie iba určitej časti signálu

Červená trieda predstavuje segmenty s najväčšou amplitúdou. Keďže K-komplex, ako je vidno na obrázku 1 má väčšiu amplitúdu než zvyšok signálu, je predpoklad že bude obsiahnutý v červenej triede a preto sa prehľadáva iba červená oblasť signálu.

### 3. Dosiahnuté výsledky

Nasledujúca tabuľka zobrazuje základné údaje o množine dát použitých pri testovaní algoritmu. Celková dĺžka záznamov predstavuje takmer 70 hodín. Použité boli spánkové záznamy malých detí vo veku 6 - 15 rokov.

Tabuľka 1: Základné údaje o použitých záznamoch

Vek pacienta	ID (identifikačné číslo)	Pohlavie	Dĺžka záznamu v hodinách
6	3	Ž	10:06:30
8	5	Ž	09:08:30
8	6	Ž	07:03:30
9	4	M	08:57:00
11	1	Ž	07:44:00
15	2	M	09:42:30

Úspešnosť detekcie navrhnutého algoritmu zobrazuje tabuľka 2.

Tabuľka 2: Úspešnosť detekcie K-komplexu v jednotlivých záznamoch

Vek pacienta	ID (identifikačné číslo)	Pohlavie	Úspešnosť [%]
6	3	Ž	87,91
8	5	Ž	47,86
8	6	Ž	53,50
9	4	M	81,72
11	1	Ž	82,00
15	2	M	67,91

Úspešnosť navrhnutého algoritmu je v priemere približne 70%, čo je uspokojivý výsledok, na ktorom sa dá stavať a vylepšovať samotnú detekciu K-komplexu. Zdokonaľovaním detekcie sa zvýši aj percento správneho skórovania stavu NREM2.

### 4. Záver

Článok rozoberá jednu z možných metód pre detekciu K-komplexu v niekoľkohodinovom zázname spánkového EEG. Pre detekciu je použitá jednoduchá neurónová sieť. Vyhľadávací algoritmus bol testovaný na šiestich záznamoch detských spánkových EEG. Priemerná úspešnosť detekcie je 70%. Daný výsledok vytvára dobrý východiskový bod pre ďalšie zdokonaľovanie vyhľadávacieho algoritmu, čo povedie k presnejšiemu skórovaniu spánkového stavu NREM2. Je potrebné rozšíriť tréningovú skupinu K-komplexov aby bola sieť univerzálnejšia. Z tohto dôvodu je veľmi potrebná

---

ďalšia kooperácia s neurológom.

### **Literatúra**

1. LOPES DA SILVA, F.: Electroencephalography: Basic Principles, Clinical Applications and Related Fields. Baltimore, MD, USA, Urban and Schwanzenberg, 1982, s 685-711.
2. RECHTSCHAFFEN, A., KALES, A. A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects. Washington DC. 1968.
3. [3] IBER, C., ANCOLI, S., CHESSON, A. The AASM Manual of the Scoring of Sleep and Associated Events. American Academy of Sleep Medicine, Westchester, USA, 2007.
4. [4] MOHYLOVÁ, J., KRAJČA, V. Zpracování signálu v lékařství. 2005, ISBN 8080703418.
5. [5] VONDRÁK, I. Umělá inteligence a neuronové sítě. skriptum VŠB - TU Ostrava, 1994
6. [6] ARBIB, MICHAEL A.: The Handbook of Brain Theory and Neural Networks. 1995, ISBN 9780262011488.
7. [7] WILKES, A.L. & WADE, N.J. Bain on Neural Networks. Brain and Cognition, 1997, s 295-305.
8. [8] CLARK, J.W., RAFELSKI, J., WINSTON, J.W. Brain without mind: computer simulations of neural networks with modifiable neuronal interactions. Physics Report, University of Cape Town. 1985.
9. [9] KARDI, T. K-Mean Clustering Tutorials [online]. [cit. 2007-11-12]. Dostupný z WWW: <<http://people.revoledu.com/kardi/tutorial/kMean/index.html>>.

---

Spoluautorom článku je Ing. Branko Babušiak, PhD., Katedra teoretickej elektrotechniky a biomedicínskeho inžinierstva, Elektrotechnická fakulta, Žilinská univerzita

---