



ZPRACOVÁNÍ A ANALÝZA BIOSIGNÁLŮ V.



ELEKTROENCEFALOGRAM

ZPRACOVÁNÍ V ČASOVÉ OBLASTI

ANALÝZA EEG

POUŽÍVANÉ PROSTŘEDKY

☑ **frekvenční analýza**

- **stacionární analýza** – testy stacionarity, FFT, neparametrické a parametrické metody
- **nestacionární analýza** – časový vývoj frekvenčního spektra, časově-frekvenční transformace,

☑ **analýza v časové oblasti**

- **detekce grafoelementů** - mimetické metody, korelační analýza, ...


☑ **mapování**

- **metody zpracování obrazů** - korekce neostrotí, analýza vzájemných souvislostí, lokalizace zdrojů, modely, ...

STACIONARITA ADAPTIVNÍ SEGMENTACE

METODA TESTOVACÍHO A REFERENČNÍHO OKNA


- na začátek segmentu se umístí pevné referenční okno; v něm se určí charakteristiky signálu;
- po signálu klouže pohyblivé testovací okno a v něm se rovněž průběžně počítají charakteristiky;
- z rozdílu charakteru signálu v obou oknech se určí míra difference (odchylka od stacionarity)
- jakmile difference překročí mez, je indikována změna stacionarity signálu
- přesná poloha hranice se určí z okolního průběhu;
- referenční okno se posune na začátek nového segmentu a pořád dokolečka;



STACIONARITA ADAPTIVNÍ SEGMENTACE

METODA DVOU SPOJENÝCH OKEN

- po signálu kloužou dvě spojená okna
- z rozdílu charakteru signálu v obou oknech se určí míra difference (odchylka od stacionarity)
- hranice segmentu je v místě lokálního maxima míry difference; vliv nevýznamných fluktuací míry difference je omezen minimální mezí pro segmentaci



STACIONARITA ADAPTIVNÍ SEGMENTACE

MÍRY DIFERENCE

- ✓ odhad střední hodnoty - $A_w = \sum |x_i|$
- ✓ odhad střední frekvence - $F_w = \sum |x_i - x_{i-1}|$
(předpoklad: průměrná diference \sim střední frekvenci)
- ✓ vážená kombinace obou hodnot
- ✓ odhad autokorelační funkce

STACIONARITA ADAPTIVNÍ SEGMENTACE

MÍRY DIFERENCE



$$\text{DIFF} = \sum_{n=0}^{\text{ACFL}} \frac{R_{w1}(n) - R_{w2}(n)}{R_{w1}(0) \cdot R_{w2}(0)}$$

kde R_w je autokorelační funkce oken $w1$ a $w2$, ACFL je počet koeficientů AKF



$$\text{DIFF} = \max_w \left\{ \frac{1}{2} \left[\frac{X_t(\omega)}{Y_t(\omega)} + \frac{Y_t(\omega)}{X_t(\omega)} \right] - 1 \right\}$$

kde X_t a Y_t označují odhad spektrálního obsahu v oknech spočítaný pomocí DFT + vyhlazení

NEZÁCHVATOVÉ EEG

- ☑ **mimetické metody** (metody napodobující analýzu člověkem)



výhradně v časové oblasti – měření dob trvání a velikostí jednotlivých vln, počet vln za jednotku času, rytmus

NEZÁCHVATOVÉ EEG DEKOMPOZICE VLN


periodová analýza – (historicky první)

- EEG se posuzuje jako posloupnost půlvln se začátky a konci v místech průchodu nulovou linií – **originál, 1. derivace, 2. derivace**


ačkoliv je ignorována velikost signálu, je signál dostatečně přesně zakódován pomocí časových intervalů

největší výhody:

jednoduchost kódování, přímý vztah mezi časovými mírami a způsobem analýzy člověkem



NEZÁCHVATOVÉ EEG DEKOMPOZICE VLN




- ✓ histogramy časových intervalů
- ✓ dominantní frekvence \sim průměrný počet průchodů nulou v originálním signálu
- ✓ „rychlá“ aktivita ve zbývajících histogramech; vztah mezi histogramy a frekvenčními spektry
- ✓ nevýhody:
 - citlivost na vf šum (EMG) – β a γ aktivita
 - absence přesného měření velikostí vln (? úroveň izolinie)

NEZÁCHVATOVÉ EEG DEKOMPOZICE VLN

analýza (detekce) vrcholů

detekce extrémů + extrakce pravděpodobného šumu
velikost + doba mezi extrémy

vyhodnocení: průměrná frekvence, průměrná
amplituda v hlavních frekvenčních pásmech



NEZÁCHVATOVÉ EEG DEKOMPOZICE VLN

analýza (detekce) vrcholů

napravuje:

- ☑ citlivost na artefakty, nedostatek informace o úrovni signálu

nenapravuje:

- ☑ oddělení společně existujících aktivit s různými frekvencemi (tj. jak detekovat pomalé složky při existenci rychlých složek)

NEZÁCHVATOVÉ EEG DEKOMPOZICE VLN

analýza period a vln

měření dob mezi průchody nulou + měření „amplitud“ mezi vrcholy


problém superponovaných aktivit

– úzkopásmové PP s pásmy
základních frekvencí EEG

statistické vyhodnocení:

střední hodnota, variance
frekvence, ...

výhoda: kvantitativní data
komplementární analýze
prováděné lidmi




NEZÁCHVATOVÉ EEG

☑ AUTOMATICKÁ DETEKCE HROTŮ A OSTRÝCH VLN (Spike&Sharp Wave – SSW)

epilepsie - náhlý začátek a konec úseků SSW nebo repetičních, rytmických úseků (3/s komplex vrchol/vlna).

!!! PROBLÉM !!! – co je to hrot ??

EEG hrot je: „... přechodová aktivita, kterou lze rozpoznat od pozadí, ve tvaru vrcholu a o trvání 20 – 70 ms. Hlavní složka je obecně záporná ve srovnání s ostatními segmenty. Velikost je proměnná.“



NEZÁCHVATOVÉ EEG

hroty mohou být monofázické, polyfázické;
dominantní kritérium vychází ze strmosti –
průměrný maximální sklon: $8\mu\text{V}/\text{ms}$

vazba na pomalejší **vlnu** – úrovňové poměry se
mění

kontextová analýza ve více signálech paralelně

epileptická stimulace – hyperventilace,
fotostimulace, přechodné stavy vědomí, fáze
spánku

hodnocení lékaři – spíše konzervativní, vyloučit
falešně pozitivní nálezy

ZÁCHVATOVÉ EEG

METODY DETEKCE SSW

- ✓ **korelace a souhlasná filtrace**
- ✓ **inverzní filtrace**
- ✓ **heuristické prohledávání**
- ✓ **diskriminační analýza**

ZÁCHVATOVÉ EEG


KORELACE A SOUHLASNÁ FILTRACE

✓ korelace

výpočet korelačního koeficientu - velká proměnnost tvaru SSW \Rightarrow rozsáhlá množina vzorů - hodnota prahu ?!?

✓ souhlasná filtrace (viz EKG)

\rightarrow není spektrální odlišení SSW a pozadí \Rightarrow sada souhlasných filtrů
práh opět ve $\star \star \star \star$



ZÁCHVATOVÉ EEG

INVERZNÍ FILTRACE

- ☑ předpoklad, že spontánní aktivita je modelována jako výstup AR filtru

$$y(nT) = \sum_{i=1}^L a_i y(nT-iT) + e(nT)$$

↓

$$H(z) = \frac{Y(z)}{E(z)} = \frac{1}{1 + a_1 z^{-1} + \dots + a_L z^{-L}}$$

inverzní autoregresivní filtr

$$I(z) = \frac{E(z)}{Y(z)} = 1 + a_1 z^{-1} + \dots + a_L z^{-L}$$

ZÁCHVATOVÉ EEG INVERZNÍ FILTRACE

- ☑ podle předpokladu by EEG vyfiltrované filtrem s $I(z)$ měl být stacionární. bílý, normální šum




odchyly ve výstupu IARFod bělosti – **přítomnost nestacionarity**

neAR modely jsou citlivější na FP detekce, citlivost na FP obecně



potřeba následného zpracování

šikovné nastavení prahů,
koeficientů inverzních filtrů
(úseky signálu pro učení)



ZÁCHVATOVÉ EEG

HEURISTICKÉ METODY

opět mimetické metody vs. optimální metody

vyhledáváme útvary podle důležitých parametrů (trvání, křivost,...)

kritéria podle velikosti, trvání, křivosti

- předpokládáme, že to, co chceme najít, lze v signálu snadno rozlišit od pozadí (což není vždy pravda – např. delta aktivita ve spánku stav III, IV)

ZÁCHVATOVÉ EEG


HEURISTICKÉ METODY

☑ křivost

→ 2. derivace – předtím
filtrace (jaká?)

náhražky snadno
spočitatelné – lineární
aproximace

B, D v polovině mezi AC a CE



ZÁCHVATOVÉ EEG

HEURISTICKÉ METODY

☑ měření času

průchody nulou signálu a jeho derivací
snižování citlivosti derivací na šum (např.
kvantování) – náhrada polynomy (např. nejmenší
čtverce 2. řád z 5 bodů)

☑ strmost

totéž co křivost, práh $\sim 2\mu\text{V}/\text{ms}$

ZÁCHVATOVÉ EEG

HEURISTICKÉ METODY

- ☑ kombinace více parametrů zvyšuje spolehlivost
 - doba mezi dvěma extrémy (následnými);
 - doba mezi dvěma následnými inflexními body;
 - velikost extrému vzhledem k nulové izolinii;
 - sklon – extrém 1. derivace (diference) v rostoucím, resp. klesajícím úseku
 - křivost – extrém 2. derivace (diference)
- ☑ další redundance – více svodů

ZÁCHVATOVÉ EEG

HEURISTICKÉ METODY

- ☑ nastavení parametrů – zkusmo
- ☑ nastavení prahů
 - maximalizace **sensitivity** (poměr správných detekcí k celkovému počtu) a **specificity** (poměr správně nezachycených případů k celkovému počtu artefaktů);
 - proměnné prahy
 - doplňková logická pravidla

ZÁCHVATOVÉ EEG

DISKRIMINAČNÍ ANALÝZA

- ☑ **prostředek pro zautomatizování výběru parametrů, prahů a vlastního rozpoznávání**
 - výběr parametrů z vytvořené množiny;
 - transformace proměnných (parametrických, příznakových)
 - definice a určení diskriminačních funkcí (hustota pravděpodobnosti, vzdálenost, podobnost, ...)