

# 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) –  $\beta$  a  $\gamma$  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

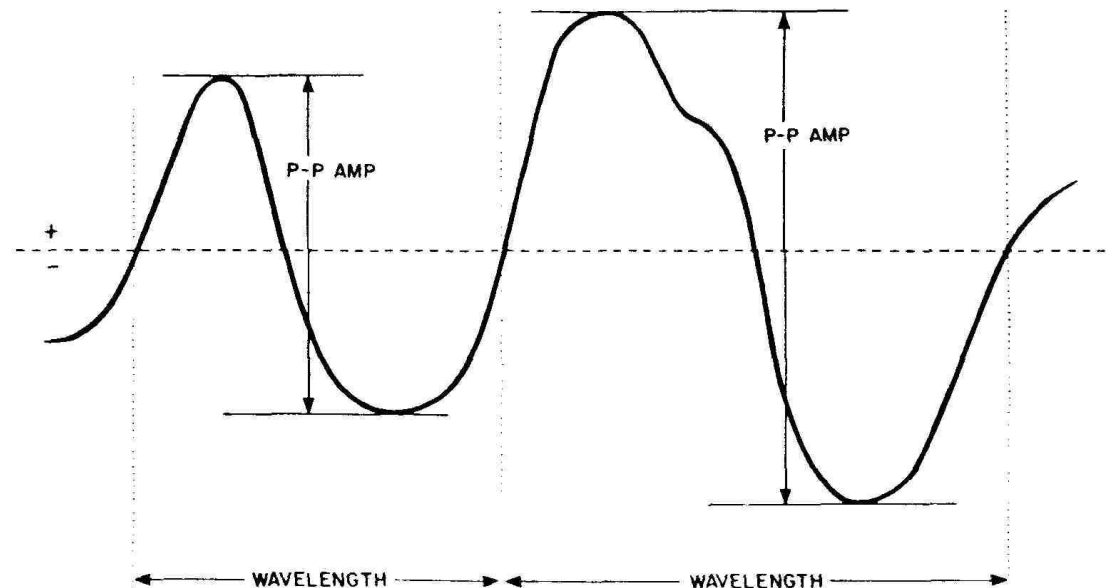
### problém superponovaných aktivit

– 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  $20 \div 70$  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** – úrovněové 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

šikovní 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, ...)