

# ZPRACOVÁNÍ A ANALÝZA BIOSIGNÁLŮ IV.



## ELEKTROKARDIOGRAM III.

## LINEÁRNÍ FILTRY

- ☑ horní propust s lineární fázovou charakteristikou s  
 $f_{\text{mez}} = f_{\text{HR}}$



třeba nejdřív zjistit HR

# LINEÁRNÍ FILTRACE DRIFTU

## ✓ filtry s NIO

nelineární fázová charakteristika – kompenzace pomocí doplňkové filtrace v inverzním čase (šup sem, šup tam)

$$\mathcal{F}\{g_n\} = \mathcal{F}\{h_n * h_{-n}\}$$

$$G(e^{j\omega T}) = H(e^{j\omega T}) \cdot H(e^{-j\omega T})$$

$$|G(e^{j\omega T})| = |H(e^{j\omega T})|^2$$

$$\arg(G(e^{j\omega T})) \equiv 0$$

- další nevýhody tytéž jako u filtrace brumu

# LINEÁRNÍ FILTRACE DRIFTU



## ☑ **filtry s KIO**

- **Lynnovy filtry** – už se o tom mluvilo, společné odstranění driftu s brumem
- dlouhá impulsní odezva  $\Rightarrow$  vysoká výpočetní náročnost

# LINEÁRNÍ FILTRACE DRIFTU

## ✓ filtry s KIO

filtrace s  
decimací  
vzorkovacího  
kmitočtu



# FILTRACE DRIFTU • SPLAJNY

**splajn** (spline) je po částech polynomická funkce, která má v každém aproximačním intervalu stupeň nejvýše  $r$  a její derivace jsou do řádu  $r-1$  všude spojité

(aproximace lomenou přímkou je splajn 1. řádu)

# FILTRACE DRIFTU • SPLAJNY

interpolace signálu ze znalosti hodnot ve vybraných uzlových bodech (body v PQ intervalech) kubickým polynomem

$$n(t) = n'''(0).t^3/6 + n''(0).t^2/2 + n'(0).t + n(0)$$

postupným derivováním polynomu získáme soustavu lineárních rovnic, která je v diskrétní podobě

$$n_{i+1} = n_i + n'_i + n''_i/2 + n'''_i/6$$


$$n'_{i+1} = n'_i + n''_i + n'''_i/2$$

$$n''_{i+1} = n''_i + n'''_i$$


$$n'''_{i+1} = n'''_i + n'''$$

- ☑ **nevýhoda** – nutnost přesného nalezení uzlových bodů

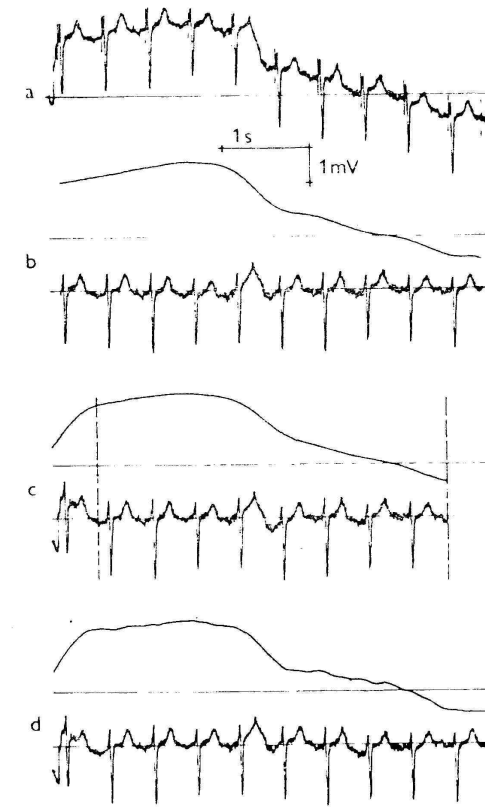
# FILTRACE DRIFTU EXPERIMENTY



Obr. 2. Filtrace driftu nulové izolácie EKG — a) vstupní signál (svislými čarami znázorněny referenční body pro aproximaci splajny); odhad průběhu driftu a výstupní signál; b) aproximace splajny; c) Linnovy horní propusti s  $f_{mez} = 0,7$  Hz; d) Linnovy horní propusti s  $f_{mez} = f_{ekg}$ ; e) algoritmu Siemens (u bodů c) a d) jsou čárkovanými čarami vyznačeny oblasti bez přechodového děje).




Obr. 3. Filtrace driftu nulové izolácie EKG — a) vstupní signál (svislými čarami znázorněny referenční body pro aproximaci splajny); odhad průběhu driftu a výstupní signál b) aproximace splajny (ve 4. cyklu chybně určen referenční bod); c) Linnovy horní propusti s  $f_{mez} = f_{ekg}$  (čárkovanými čarami vymezena oblast bez přechodového děje).



Obr. 4. Filtrace driftu nulové izolácie EKG — a) vstupní signál (svislými čarami znázorněny referenční body pro aproximaci splajny); odhad průběhu driftu a výstupní signál b) aproximace splajny; c) Linnovy horní propusti s  $f_{mez} = f_{ekg}$  (čárkovanými čarami vymezena oblast bez přechodového děje); d) algoritmu Siemens.



# FILTRACE DRIFTU ADAPTIVNÍ FILTRY



$$y(n) = w(n)$$

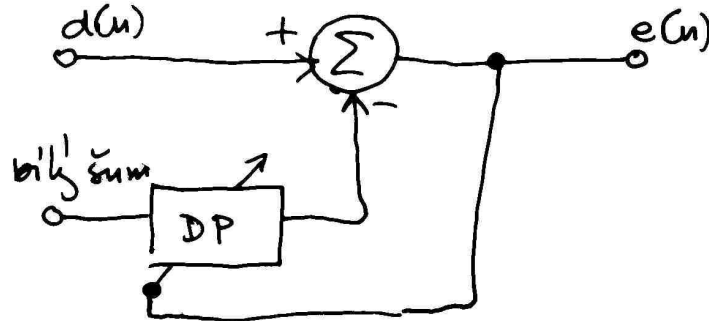
$$e(n) = d(n) - y(n) = d(n) - w(n)$$

LMS algoritmus

$$w(n+1) = w(n) + 2\mu e(n) =$$

$$= w(n)(1 - 2\mu) + 2\mu d(n)$$

$$\mu = \frac{\mu_{max}}{n} \dots \text{sířka pásma}$$



# MYOPOTENCIÁLY


- ☑ překrývání spekter rušení a užitečného signálu  $\Rightarrow$  lineární filtry ???
- ☑ Draft IEC62D ...  $f_{\text{mezDP}|_{3\text{dB}}} \in \langle 35; 45 \rangle$  Hz  
sklon amplitudové charakteristiky v ZP max. - 6dB/okt.

# MYOPOTENCIÁLY ZPRŮMĚŘOVÁNÍ

$$y(t + kT) = x(t + kT) + n(t + kT)$$

- signál  $x(t)$  je časově invariantní;
- $n(t)$  je aditivní a nekorelovaný s  $x(t)$ ;
- $n(t)$  je stacionární;
- $n(t)$  má normální rozložení s nulovým průměrem;

# MYOPOTENCIÁLY ZPRŮMĚŘOVÁNÍ



# MYOPOTENCIÁLY ZPRŮMĚŘOVÁNÍ

$$\tilde{y}(t) = \frac{1}{N} \sum_{k=0}^{N-1} y(t+kT) = \frac{1}{N} \sum_{k=0}^{N-1} r(t+kT) + \frac{1}{N} \sum_{k=0}^{N-1} n(t+kT)$$

$$\tilde{y}(t) = r(t) + \frac{1}{N} \sum_{k=0}^{N-1} n(t+kT)$$

$$E[\tilde{y}(t)] = E[r(t)] + \frac{1}{N} E\left[\sum_{k=0}^{N-1} n(t+kT)\right], \quad 0 \leq t < T$$


protože  $E[n(t)]=0$  je

$$E[\tilde{y}(t)] = r(t)$$

# MYOPOTENCIÁLY ZPRŮMĚŘOVÁNÍ

- rovnoměrné váhy
- exponenciální váhy
- adaptivní váhy podle obsahu šumu

# REDUKCE DAT



# REDUKCE DAT

PROČ?

PROTO: - přenos dat } vratná redukce  
- uchování dat }  
- snazší zpracování dat (reálný čas) } nevratná  
- klasifikace } redukce

METODY

! neadaptivní - parametry redukčního systému jsou furt stejné používají se pro signály o známých dostatečně časově stálých vlastnostech

adaptivní - parametry redukčního systému se přizpůsobují okamžitým charakteristikám signálu; s výhodou se používají tam, kde charakteristiky signálu nejsou předem známy



# REDUKCE DAT

## ALGORITMY VRATNÉ REDUKCE

- ☑ odstranění deterministické složky signálu

$$e(n) = f(n) - f_e(n)$$

$e(n)$  ... hodnota  $n$ -tého vzorku  
nedeterministické složky signálu;

$f(n)$  ... vzorek původního signálu;

$f_e(n)$  ... odhad původní hodnoty signálu,  
představující hodnotu vzorku deterministické  
složky signálu

# REDUKCE DAT

## ALGORITMY VRATNÉ REDUKCE

### ☑ predikční odhad

$$f_{ep}(n) = \sum_{j=1}^m a_j \cdot f(n-j)$$

$m \geq 1$ .... řád prediktoru

$a_j$  ... váhový koeficient hodnoty  $f(n-j)$  původního signálu

# REDUKCE DAT

## ALGORITMY VRATNÉ REDUKCE

### ☑ interpolační odhad

$$f_{ei}(n) = \sum_{j=1}^k a_j \cdot f(n-j) + \sum_{j=1}^l b_j \cdot f(n+j)$$

$$m = k + l \quad (k \geq 1; l \geq 1)$$

$a_j, b_j \dots$  váhové interpolační koeficienty

# REDUKCE DAT

## ALGORITMY VRATNÉ REDUKCE

### ☑ **diferenční odhad**

$$e(n) = d^{(m)}(n) = f(n) - \binom{m}{1}f(n-1) + \binom{m}{2}f(n-2) - \dots + (-1)^{m+1}f(n-m)$$

$$f_{ed}(n) = \binom{m}{1}f(n-1) - \binom{m}{2}f(n-2) + \dots + (-1)^{m+1}f(n-m)$$

zatímco funkci predikčního a interpolačního algoritmu určují řád i koeficienty, v případě diferenčního algoritmu jen řád

# REDUKCE DAT

## ALGORITMY VRATNÉ REDUKCE

- ☑ koeficienty  $a_j$ ,  $b_j$  závisí na statistických vlastnostech signálu
- ☑ určí se různě – např. dle kritéria minimální střední kvadratické chyby, které zajistí nalezení redukované zprávy s minimálním rozptylem (minimální entropií – maximální redundancí – je-li Gaussovo rozdělení)

# REDUKCE DAT

## ALGORITMY VRATNÉ REDUKCE

- ☑ řád ... empiricky max. 2

$$e(n) = f(n) - a.f(n-1) - b.f(n-2)$$

- ☑ má-li být signál obnovitelný, pak  $a_j$ ,  $b_j$  musí být celé



$$a = 2; b = -1$$


$$a = 1; b = 0$$

# REDUKCE DAT


## ALGORITMY VRATNÉ REDUKCE

### redukční a rekonstrukční algoritmus

redukční algoritmus



rekonstrukční algoritmus



$$f(n) = e(n) + a_1 f(n-1) + a_2 f(n-2)$$

na mezi stabilitě - pozor na možnost poruč

# REDUKCE DAT


## ALGORITMY VRATNÉ REDUKCE

### kódy s minimální redundancí

Huffmanův kód

$x_i$	$P(x_i)$	konstrukce	kód
$x_1$	0,32		11
$x_2$	0,24		01
$x_3$	0,18		00
$x_4$	0,12		100
$x_5$	0,08		1011
$x_6$	0,06		1010

dekódovací strom





# REDUKCE DAT

## ALGORITMY VRATNÉ REDUKCE


### kódy s minimální redundancí

#### Shannonův-Fanův kód

#### Shannonův-Fanův kód

$x_i$	$P(x_i)$	konstrukce	kód
$x_1$	0,32	0,58 } 0	00
$x_2$	0,24		0 } 1
$x_3$	0,18	0,44 } 0	10
$x_4$	0,12		0 } 0
$x_5$	0,08	1 } 1 } 0	1110
$x_6$	0,06		1 } 1

#### dekódovací strom






# REDUKCE DAT

## ALGORITMY NEVRATNÉ REDUKCE

- ☑ úsek signálu je nahrazen s určitou tolerancí funkcí, jejíž parametry reprezentují průběh reálných dat

predikce polynomem 1. řádu




optimalizace délky úseků (iterační):

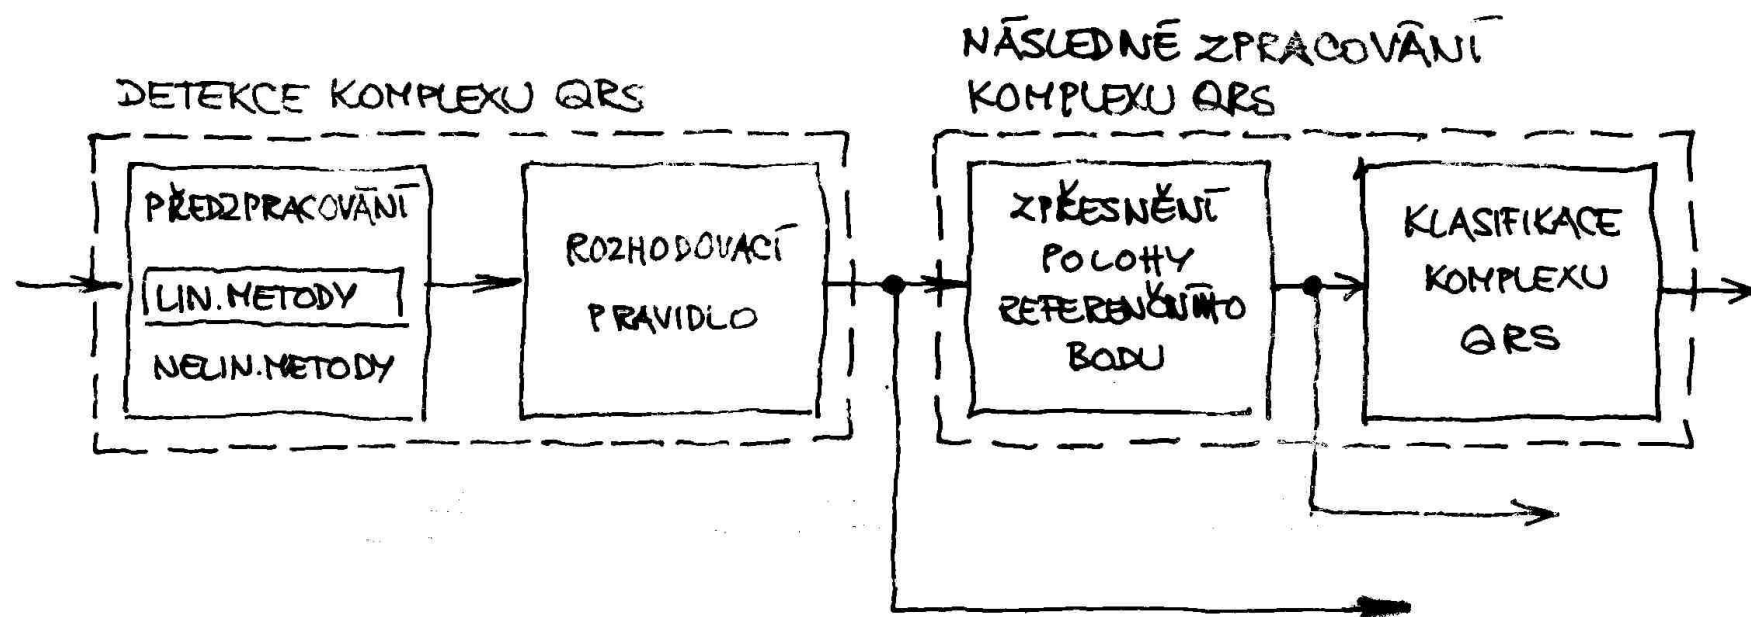
1. optimalizace polohy bodu zlomu
2. spojování sousedních úseků, nepřekročí-li chyba spojeného úseku povolenou mez
3. vzdělování úseků, jejichž chyba přesahuje povolenou toleranci v místě maximální chyby

# DETEKCE VLN V SIGNÁLU EKG

- ☑ komplex QRS
- ☑ vlna P;
- ☑ vlna T



# DETEKCE KOMPLEXU QRS



# DETEKCE KOMPLEXU QRS

- ☑ problémy detekce QRS:
- ☑ změny morfologie fyziologického původu;
- ☑ změny morfologie způsobené technickými artefakty
  - myopotenciály
  - přechodné artefakty způsobené elektrodami
  - síťové rušení
- ☑ vysoké vlny P a T

# DETEKCE KOMPLEXU QRS



# DETEKCE KOMPLEXU QRS PŘEDZPRACOVÁNÍ

## ☑ **lineární metody**

souhlasná filtrace (matched filtering) ...  
přizpůsobené filtry

(filtrace systémem s impulsní charakteristikou,  
která má časově inverzní průběh, než  
detekovaný signálový prvek)

# DETEKCE KOMPLEXU QRS PŘEDZPRACOVÁNÍ

## ✓ lineární metody souhlasná filtrace

SOUHLASNĚ FILTRY :

PŘENOSOVÁ FUNKCE SOUHLASNĚHO FILTRU

$$K(j\omega) = c_1 \cdot S^*(j\omega) \cdot e^{-j\omega t_0}$$

kde  $S(j\omega)$  je spektrální funkce hledaného užitečného signálu

IMPULSOVÁ ODEZVA SOUHLASNĚHO FILTRU

$$k(nT) = c_2 \cdot s(-nT),$$

kde  $s(nT)$  je průběh hledaného užitečného signálu

VÝSTUPNÍ SIGNÁL PODLE KONVOLUČNÍHO TEOREMU

$$y(nT) = \sum_{u=0}^{M-1} x(uT) \cdot k(nT - uT) = c_2 \sum_{u=0}^{M-1} x(uT) \cdot s(uT - nT)$$

DISKRÉTNÍ KORELAČNÍ FUNKCE POSLOUPNOSTÍ  $x(nT)$  A  $s(nT)$

$$B_{sx}(nT) = \sum_{u=0}^{M-1} x(uT) \cdot s(uT - nT)$$



# DETEKCE KOMPLEXU QRS PŘEDZPRACOVÁNÍ

## ☑ **lineární metody**

?! možné změny průběhu komplexů QRS  $\Rightarrow$  nelze klást konkrétní požadavky na časově invariantní filtr  $\Rightarrow$  je třeba vycházet z obecných vlastností

**QRS** – většina energie ve frekvenčním pásmu 5 ÷ 30 Hz, maximum v pásmu 10 ÷ 15 Hz, minimum rušení v pásmu 5 ÷ 20 Hz

# DETEKCE KOMPLEXU QRS PŘEDZPRACOVÁNÍ

## ☑ **nelineární metody**

práce s jedním svodem  $\times$  s více svody

→ jeden svod - menší výpočetní náročnost;  
menší množství informace; možnost selhání  
při upadnutí svodu

1. určitě více než jeden, v případě že existuje;
2. max. 3 vyjadřují-li prostorovou aktivitu

# DETEKCE KOMPLEXU QRS

## PŘEDZPRACOVÁNÍ

- ☑ **nelineární metody**  
vícesvodová detekce

modul vektoru prostorové rychlosti

$$z(n) = (\Delta x^2(n) + \Delta y^2(n) + \Delta z^2(n))^{1/2}$$

čtverec modulu vektoru prostorové rychlosti

$$z(n) = \Delta x^2(n) + \Delta y^2(n) + \Delta z^2(n)$$

funkce absolutních hodnot diferencí srovnávací napětí

$$z(n) = |\Delta x| + |\Delta y| + |\Delta z|$$

koincidenční funkce

$$z(n) = \Delta x \cdot \Delta y \cdot \Delta z$$

modul vektoru prostorového napětí

$$z(n) = (x^2(n) + y^2(n) + z^2(n))^{1/2}$$

diference modulu vektoru prostorového napětí

$$z(n) = \Delta((x^2(n) + y^2(n) + z^2(n))^{1/2})$$

# DETEKCE KOMPLEXU QRS PŘEDZPRACOVÁNÍ

## ☑ **nelineární metody**

zvýraznění větších hodnot signálu a potlačení malých hodnot signálu

→ umocnění

→  $z(nT) = y^2(nT) * h_e(nT)$ , kde  $y(nT)$  je hodnota první diference nebo filtrovaného vstupního signálu

# DETEKCE KOMPLEXU QRS

## ROZHODOVACÍ KRITÉRIA

### ☑ **základní prahová kritéria**

- srovnání signálu s pevným prahem
- kombinace pevného strmostního kritéria a detektoru maxima

$$(x_i - x_{i-1}) \cdot (x_{i+1} - x_i) < 0$$

$$|x_i - x_{i-1}| > K$$

- detektor maxima s dvouprůchodovým detektorem prahovou úrovní

# DETEKCE KOMPLEXU QRS

## ROZHODOVACÍ KRITÉRIA

### ✓ adaptivní prahová kritéria

- proměnný práh  $\times$  proměnné zesílení signálu;
- proměnný práh podle dlouhodobých změn v signálu

$\times$

proměnný práh během srdečního cyklu

$$\alpha_1 \quad \text{pro } n = \tau + 1, \dots, \tau + D_1$$

$$\Theta(n) = f(n) \quad \text{pro } n = \tau + D_1 + 1, \dots, \tau + D_2$$

$$\alpha_2 \quad \text{pro } n = \tau + D_2 + 1, \dots,$$

kde  $f(n)$  je monotónně klesající a  $\alpha_1 \geq f(n) \geq \alpha_2$  ;

- logická pravidla;

# DETEKCE KOMPLEXU QRS

## ROZHODOVACÍ KRITÉRIA

### ☑ **sekvenční prahové algoritmy**

- využívají znalosti vlastností signálu před i po okamžiku zpracování