



SPEKTRÁLNÍ ANALÝZA ČASOVÝCH ŘAD



prof. Ing. Jiří Holčík, CSc.

holcik@iba.muni.cz

© Institut biostatistiky a analýz

V. PARAMETRICKÉ METODY ODHADU VÝKONOVÉHO SPEKTRA

PARAMETRICKÉ METODY

- ☑ extrapolují hodnoty autokorelační funkce pro $m \geq N$ (k tomu je potřeba apriorní informace o analyzovaném signálu)



parametrický model vzniku signálu a z toho už cokoliv

tedy: netrápí nás okna, ani prosakování spekter \Rightarrow lepší rozlišovací schopnost i při krátkých záznamech \Rightarrow **analýza časově proměnných a přechodných dějů**

MODEL SIGNÁLU PRŮCHODEM LINEÁRNÍ SOUSTAVOU

$$H(z) = \frac{Y(z)}{X(z)} = \frac{\sum_{k=0}^q b_k z^{-k}}{1 + \sum_{k=1}^p a_k z^{-k}}$$

$$y(nT) = -\sum_{k=1}^p a_k y((n-k)T) + \sum_{k=0}^q b_k x((n-k)T)$$

MODEL SIGNÁLU PRŮCHODEM LINEÁRNÍ SOUSTAVOU

- ☑ je-li posloupnost $x(nT)$, resp. $y(nT)$ realizací stacionárního náhodného procesu, platí pro jejich spektrální výkonové hustoty $\Gamma_{xx}(f)$, resp. $\Gamma_{yy}(f)$,

$$\Gamma_{yy}(f) = |H(f)|^2 \cdot \Gamma_{xx}(f),$$

kde $|H(f)|$ je modul frekvenční charakteristiky použité lineární soustavy.

MODEL SIGNÁLU PRŮCHODEM LINEÁRNÍ SOUSTAVOU

Je-li $x(nT)$ bílý šum s nulovou střední hodnotou, pak jeho autokorelační funkce

$$\gamma_{xx}(mT) = \begin{cases} \sigma_x^2 & m = 0 \\ 0 & m \neq 0 \end{cases} \quad \text{a} \quad \Gamma_{xx}(f) = \sigma_x^2$$

σ_x^2 je rozptyl posloupnosti $x(nT)$, tj. $\sigma_x^2 = E[x^2(nT)]$ a pro spektrální hustotu výkonu výstupní posloupnosti platí

$$\Gamma_{yy}(f) = \sigma_x^2 \cdot |H(f)|^2 = \sigma_x^2 \cdot \frac{|Y(f)|^2}{|X(f)|^2}$$

MODEL SIGNÁLU PRŮCHODEM LINEÁRNÍ SOUSTAVOU

Algoritmy parametrického odhadu výkonového spektra posloupnosti $y(nT)$, $n \in \langle 0, N-1 \rangle$ obsahují:

- 1) odhad parametrů modelu přenosové soustavy;
- 2) výpočet spektrální hustoty výkonu $\Gamma_{yy}(f)$ z odhadnutých parametrů

MODEL SIGNÁLU PRŮCHODEM LINEÁRNÍ SOUSTAVOU

☑ podle charakteru modelu přenosové soustavy dělíme algoritmy na:

→ ARMA(p,q) – autoregressive-moving average řádu (p,q);

→ AR(p), $q=0$, $b_0=1$, $H(z)=1/X(z)$...

... autoregresivní

→ MA(q), $X(z) = 1 \Rightarrow H(z) = Y(z)$...

moving average

MODEL SIGNÁLU PRŮCHODEM LINEÁRNÍ SOUSTAVOU

- ☑ nejčastěji používaný AR model – proč?
 - ➔ vhodný pro vyjádření spektra s úzkými vrcholy (rezonance)
 - ➔ výpočet parametrů vede na jednoduchou soustavu lineárních rovnic
 - ➔ Lacoss (1971) – (platí pro všechny AR modely):
 - ☐ spektrální vrcholy odhadu spektra harmonických signálů pomocí AR modelu jsou úměrné čtverci výkonu harmonických signálů;
 - ☐ plocha vrcholu výkonové spektrální hustoty je lineárně úměrná výkonu harmonického signálu

MODEL SIGNÁLU PRŮCHODEM LINEÁRNÍ SOUSTAVOU

- ☑ dekompoziční teorém (Wold 1938)
 - jakýkoliv ARMA nebo MA proces může být jednoznačně reprezentován AR modelem max. ∞ řádu;
 - jakýkoliv ARMA nebo AR proces lze reprezentovat MA modelem max. ∞ řádu;



je nám jedno, co použijeme za model, jen by měl mít co nejméně parametrů, které se snadno počítají

ZÁKLADNÍ VZTAHY MEZI PARAMETRY MODELU A AUTOKORELAČNÍ POSLOUPNOSTÍ

ARMA:

$$y(nT) = - \sum_{k=1}^p a_k y(nT - kT) + \sum_{k=0}^q b_k x(nT - kT) \quad | \cdot y(nT - mT), \mathbb{E}$$

$$\mathbb{E}[y(nT) \cdot y(nT - mT)] = - \sum_{k=1}^p a_k \cdot \mathbb{E}[y(nT - kT) y(nT - mT)] + \sum_{k=0}^q b_k \cdot \mathbb{E}[x(nT - kT) \cdot y(nT - mT)]$$

$$r_{yy}(mT) = - \sum_{k=1}^p a_k \cdot r_{yy}(mT - kT) + \sum_{k=0}^q b_k \cdot r_{xy}(mT - kT)$$

$r_{xy}(mT)$... křížově korelační posloupnost mezi $x(nT)$ a $y(nT)$

$$r_{xy}(mT) = \mathbb{E}[y(nT) \cdot x(nT + mT)] = \mathbb{E}\left[\sum_{k=0}^{\infty} h(kT) \cdot x(nT - kT) \cdot x(nT + mT)\right] =$$

$$= \sum_{k=0}^{\infty} h(kT) \cdot \mathbb{E}[x(nT) x(nT + mT + kT)] = \sum_{k=0}^{\infty} h(kT) \cdot r_{xx}(mT + kT) =$$

$$= h(-mT) \cdot \sigma_x^2 = \begin{cases} 0 & m > 0 \\ \sigma_x^2 h(-mT) & m \leq 0 \end{cases}$$

ZÁKLADNÍ VZTAHY MEZI PARAMETRY MODELU A AUTOKORELAČNÍ POSLOUPNOSTÍ

ARMA (pokračování):

$$\gamma_{yy}(mT) = \begin{cases} - \sum_{k=1}^p a_k \cdot \gamma_{yy}(mT - kT) & m > q \\ - \sum_{k=1}^p a_k \cdot \gamma_{yy}(mT - kT) + \sigma_x^2 \sum_{k=0}^{q-m} h(k) \cdot b_{k+m} & 0 \leq m \leq q \\ \gamma_{yy}(-mT) & m < 0 \end{cases}$$

nelineární vztah mezi $\gamma_{yy}(mT)$ a parametry a_k a b_k

ZÁKLADNÍ VZTAHY MEZI PARAMETRY MODELU A AUTOKORELAČNÍ POSLOUPNOSTÍ

ARMA (pokračování):

lze rozdělit na lineární vztah pro určení parametrů a_k , $m > q$

$$\begin{bmatrix} \gamma_{yy}(q) & \gamma_{yy}(q-1) & \dots & \gamma_{yy}(q-p+1) \\ \gamma_{yy}(q+1) & \gamma_{yy}(q) & \dots & \gamma_{yy}(q-p+2) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{yy}(q+p-1) & \gamma_{yy}(q+p-2) & \dots & \gamma_{yy}(q) \end{bmatrix} \cdot \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = - \begin{bmatrix} \gamma_{yy}(q+1) \\ \gamma_{yy}(q+2) \\ \vdots \\ \gamma_{yy}(q+p) \end{bmatrix}$$

q nelineární vztah pro $0 \leq m \leq q$

jiná interpretace:

hodnoty autokorelační posloupnosti $\gamma_{yy}(mT)$, $m > q$ jsou jednoznačně určeny koeficienty charakteristického polynomu

a_k a hodnoty $\gamma_{yy}(mT)$, $0 \leq m \leq p$

z toho plyne, že lineární model automaticky definuje hodnoty autokorelační posloupnosti $\gamma_{yy}(mT)$ pro $m > q$

ZÁKLADNÍ VZTAHY MEZI PARAMETRY MODELU A AUTOKORELAČNÍ POSLOUPNOSTÍ

AR:

$$\gamma_{yy}(m) = \begin{cases} - \sum_{k=1}^p a_k \gamma_{yy}(m-k) & m > 0 \quad (q=0) \\ - \sum_{k=1}^p a_k \cdot \gamma_{yy}(m-k) + \sigma_x^2 & m = 0 \quad (0 \leq m \leq q, q=0) \\ \gamma_{yy}(-m) & m < 0 \end{cases}$$

$$\begin{bmatrix} \gamma_{yy}(0) & \gamma_{yy}(-1) & \dots & \gamma_{yy}(-p+1) \\ \gamma_{yy}(1) & \gamma_{yy}(0) & \dots & \gamma_{yy}(-p+2) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{yy}(p-1) & \gamma_{yy}(p-2) & \dots & \gamma_{yy}(0) \end{bmatrix} \cdot \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = - \begin{bmatrix} \gamma_{yy}(1) \\ \gamma_{yy}(2) \\ \vdots \\ \gamma_{yy}(p) \end{bmatrix}$$

$$\sigma_x^2 = \gamma_{yy}(0) + \sum_{k=1}^p a_k \cdot \gamma_{yy}(-k)$$

$$\begin{bmatrix} \gamma_{yy}(0) & \gamma_{yy}(-1) & \dots & \gamma_{yy}(-p) \\ \gamma_{yy}(1) & \gamma_{yy}(0) & \dots & \gamma_{yy}(-p+1) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{yy}(p) & \gamma_{yy}(p-1) & \dots & \gamma_{yy}(0) \end{bmatrix} \cdot \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma_x^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad \begin{array}{l} \text{Yule-Walderovy} \\ \text{rovnice} \end{array}$$

ZÁKLADNÍ VZTAHY MEZI PARAMETRY MODELU A AUTOKORELAČNÍ POSLOUPNOSTÍ

MA:

$$h(k) = b_k \quad 0 \leq k \leq q \quad a_k = 0 \quad 1 \leq k \leq p$$
$$0 \quad m > q$$
$$\gamma_{yy}(mT) = \begin{cases} \sigma_x^2 \cdot \sum_{k=0}^{q-m} b_k \cdot b_{k+m} & 0 \leq m \leq q \\ \gamma_{yy}(-mT) & m < 0 \end{cases}$$

AR MODELY

Yule – Walkerova metoda

výpočet odhadu autokorelace ze signálové posloupnosti $y(nT)$ a pomocí tohoto odhadu odhad parametrů \tilde{a}_k AR modelu

užitečnosti:

- 1) odhad AKF
- 2) řešení Yule-Walkerových rovnice;
- 3) odhad výkonové spektrální hustoty

AR MODELY

Yule – Walkerova metoda

$$\text{ad 1)} \quad \hat{r}_{xx}(mT) = \frac{1}{N} \cdot \sum_{n=0}^{N-|m|} x(nT) \cdot x(nT + mT)$$

\Rightarrow autokorelační matice je pozitivně semidefinitní
výsledný AR model bude stabilní

předpokládá se, že stabilní AR model reprezentuje data
nejlépe

$$\text{ad 3)} \quad \hat{P}_{xx}^{yw}(f) = \frac{\hat{\sigma}_{xp}^2 \cdot T}{\left| 1 + \sum_{k=1}^p \hat{a}_p(k) \cdot e^{-j2\pi f k T} \right|^2}$$

$$\hat{\sigma}_{xp}^2 = r_{yy}(0) \cdot \prod_{k=1}^p [1 - |\hat{a}_k(k)|^2] = \hat{E}_p^f$$

je odhad minimální střední kvadratické odchylky prediktivu p-tého řádu

AR MODELY

Yule – Walkerova metoda

ad 2) řešení Yule-Walkerových rovnic

LEVINSONŮV – DURBINŮV ALGORITMUS

LEVINSONŮV – DURBINŮV ALGORITMUS

efektivní rekurzivní algoritmus výpočtu koeficientů a_k , $k=1, \dots, p$ z Y.-W. rovnic využívající skutečnosti, že autokorelační matice má vlastnosti Toeplitcovy matice ($T(i,j)=t(i-j)$)

$$\Gamma_p = \begin{pmatrix} \gamma_{xx}(0) & \gamma_{xx}(1) & \cdots & \gamma_{xx}(p-1) \\ \gamma_{xx}(1) & \gamma_{xx}(0) & \cdots & \gamma_{xx}(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{xx}(p-1) & \gamma_{xx}(p-2) & \cdots & \gamma_{xx}(0) \end{pmatrix}$$

pracnost L.-D. algoritmu je $\mathcal{O}(p^2)$

pracnost Gaussovy eliminační metody je $\mathcal{O}(p^3)$

LEVINSONŮV – DURBINŮV ALGORITMUS

dopředná lineární predikce

normální rovnice:

$$\sum_{k=0}^p a_p(k) \gamma_{yy}(lT - kT) = 0 \quad l=1,2,\dots,p; \quad a_p(0)=1$$

výsledná minimální MSE

$$E_p^f = \gamma_{yy}(0) + \sum_{k=1}^p a_p(k) \gamma_{yy}(-kT)$$

rozšířené normální rovnice:

$$\sum_{k=0}^p a_p(k) \gamma_{yy}(lT - kT) = \begin{cases} E_p^f & l=0 \\ 0 & l=1,2,\dots,p \end{cases}$$

LEVINSONŮV – DURBINŮV ALGORITMUS

- ☑ výpočet je rekurzivní, vychází z řešení systému 1. řádu a výsledky pro systém i-tého řádu se odvozují z řešení (i-1). řádu

system 1. řádu

p=1

$$a_1(0) \cdot \gamma_{yy}(1) + a_1(1) \cdot \gamma_{yy}(0) = 0 \Rightarrow \Big|_{a_1(0)=1} a_1(1) = -\frac{\gamma_{yy}(1)}{\gamma_{yy}(0)}$$

$$E_1^f = \gamma_{yy}(0) + a_1(1) \cdot \gamma_{yy}(-1) = \gamma_{yy}(0) - \frac{\gamma_{yy}(1)}{\gamma_{yy}(0)} \cdot \gamma_{yy}(-1) =$$

$$= \gamma_{yy}(0) - \frac{|\gamma_{yy}(1)|^2}{\gamma_{yy}^2(0)} \cdot \gamma_{yy}(0) = \gamma_{yy}(0) \cdot [1 - |a_1(1)|^2]$$

LEVINSONŮV – DURBINŮV ALGORITMUS

system 2. řádu

$$p=2$$

$$a_2(0) \cdot \gamma_{yy}(1) + a_2(1) \cdot \gamma_{yy}(0) + a_2(2) \cdot \gamma_{yy}(-1) = 0$$

$$a_2(0) \cdot \gamma_{yy}(2) + a_2(1) \cdot \gamma_{yy}(1) + a_2(2) \cdot \gamma_{yy}(0) = 0$$

$$a_2(0) = 1$$

$$a_2(1) \cdot \gamma_{yy}(0) + a_2(2) \cdot \gamma_{yy}(-1) = -\gamma_{yy}(1) \quad \leftarrow \gamma_{yy}(1) = -a_1(1) \cdot \gamma_{yy}(0)$$

$$a_2(1) \cdot \gamma_{yy}(1) + a_2(2) \cdot \gamma_{yy}(0) = -\gamma_{yy}(2)$$

$$a_2(1) \cdot \gamma_{yy}(0) - a_2(2) \cdot a_1(1) \cdot \gamma_{yy}(0) = a_1(1) \cdot \gamma_{yy}(0)$$

$$a_2(1) = a_1(1) + a_1(1) \cdot a_2(2)$$

LEVINSONŮV – DURBINŮV ALGORITMUS

system 2. řádu (pokračování)

p=2

$$\gamma_{yy}(1) = -a_1(1) \cdot \gamma_{yy}(0)$$

$$a_1(1) \cdot \gamma_{yy}(1) + a_1(1) \cdot a_2(2) \cdot \gamma_{yy}(1) + a_2(2) \cdot \gamma_{yy}(0) = -\gamma_{yy}(2)$$

$$a_2(2) \cdot [\gamma_{yy}(0) - a_1^2(1) \cdot \gamma_{yy}(0)] = -\gamma_{yy}(2) - a_1(1) \cdot \gamma_{yy}(1)$$

$$a_2(2) = -\frac{\gamma_{yy}(2) + a_1(1) \cdot \gamma_{yy}(1)}{\gamma_{yy}(0) - a_1^2(1) \cdot \gamma_{yy}(0)} = -\frac{\gamma_{yy}(2) + a_1(1) \cdot \gamma_{yy}(1)}{E_1^f}$$

σ_{k-1}^2

LEVINSONŮV – DURBINŮV ALGORITMUS

obecně:

$$a_k(k) = \frac{-\gamma_{yy}(k) + \sum_{r=1}^{k-1} a_{k-1}(r) \cdot \gamma_{yy}(k-r)}{E_{k-1}^f}$$

$$a_k(i) = a_{k-1}(i) + a_{k-1}(k-i) \cdot a_k(k)$$

$$E_k^f = \sigma_k^2 = [1 - a_k^2(k)] \cdot \sigma_{k-1}^2$$

LEVINSONŮV – DURBINŮV ALGORITMUS

poznámky + užitečnosti + zajímavosti

☑ L.-D. algoritmus poskytuje odhad parametrů AR systému nejen pro požadovaný řád, nýbrž i pro všechny nižší řády;

☑ jak se správný řád pozná:

$\sigma_k^2 = E_k^f$ se v další iteraci přestane zmenšovat, resp.

$a_{p+1}(k) = a_p(k)$ pro $k=1,2,\dots,p$ a tím $a_{p+1}(p+1) = 0$

obecně pro proces AR(p) $a_k(k) = 0$ a $\sigma_k^2 = \sigma_p^2$ pro $k > p$

LEVINSONŮV – DURBINŮV ALGORITMUS

poznámky + užitečnosti + zajímavosti

- ☑ parametry $\{a_1(1), a_2(2), \dots, a_p(p)\}$ se často nazývají koeficienty reflexe K_k (název souvisí s realizací predikčních algoritmů mřížkovou strukturou);

pokud $\{\gamma_{yy}(0), \gamma_{yy}(1), \dots, \gamma_{yy}(p)\}$ je skutečná autokorelační posloupnost, tj. AK matice je pozitivně semidefinitní, pak

$$|a_k(k)| = |K(k)| \leq 1 \text{ pro } k=1, 2, \dots, p;$$

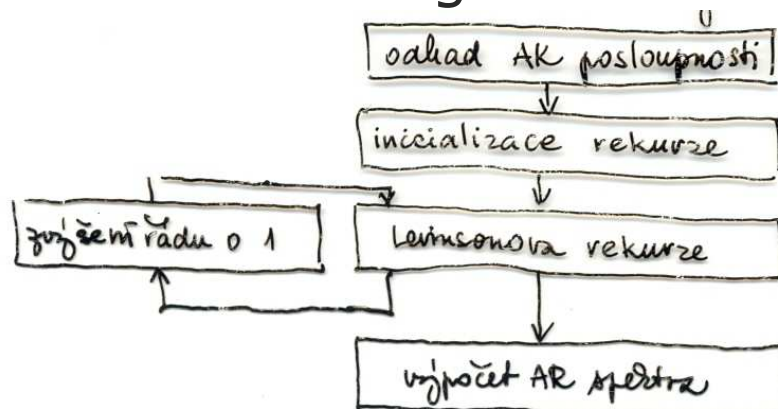
důsledky:

- $\sigma_{k+1}^2 \leq \sigma_k^2$, to znamená, že σ_k^2 dosáhne minima právě při správném řádu;
- nutnou a postačující podmínkou, aby póly $X(z)$ ležely uvnitř nebo na jednotkové kružnici v rovině z je $|K(k)| \leq 1$ pro $k=1, 2, \dots, p \Rightarrow$ AR systém je stabilní;
- je-li $|K(k)| = 1$ pro některé k , pak je třeba rekurzi ukončit, protože $\sigma_k^2 = 0 \dots$ v tom případě je proces ryze harmonický

LEVINSONŮV – DURBINŮV ALGORITMUS

poznámky + užitečnosti + zajímavosti

- ✓ pokud by byl L.-D. algoritmus implementován pomocí paralelního procesoru s optimálním počtem jednotek, je pracnost algoritmu $\mathcal{O}(p \cdot \log_2 p)$;
- ✓ při odhadu výkonového spektra harmonických signálů pomocí AR modelu jsou spektrální vrcholy AR spektra úměrné čtverci výkonu harmonických signálů;
- ✓ plocha pod spektrálními vrcholy výkonové spektrální hustoty je lineárně úměrná výkonu harmonického signálu;
- ✓ blokové schéma L.-D. algoritmu



A JE TO!