

Časové rady

Ján Pekár
Prednáška 3

ACF a predikcia

Predošlá prednáška

- Stacionarita
- Autokovariancia, autokorelácia
- Lineárne procesy MA a AR
- Výberová autokorelačná funkcia



Obsah prednášky

- Výberová autokorelačná funkcia
- ACF a predikcia
- Vlastnosti ACF



Stredná hodnota, autokovariancia, stacionarita

- Časový rad $\{X_t\}$ má funkciu strednej hodnoty $\mu_t = E[X_t]$ a autokovariančnú funkciu

$$\begin{aligned}\gamma_X(t+h, t) &= \text{Cov}(X_{t+h}, X_t) \\ &= E[(X_{t+h} - \mu_{t+h})(X_t - \mu_t)]\end{aligned}$$

Je stacionárny, ak oboje nezávisí na t .

Potom píšeme $\gamma_X(h) = \gamma_X(h, 0)$

Autokorelačná funkcia (ACF) má tvar

$$\rho_X(h) = \frac{\gamma_X(h)}{\gamma_X(0)} = \text{Corr}(X_{t+h}, X_t)$$



Lineárne procesy

- Dôležitá trieda stacionárnych časových radov

$$X_t = \mu + \sum_{j=-\infty}^{\infty} \psi_j W_{t-j}$$

kde

$$\{W_t\} \sim WN(0, \sigma_w^2)$$

a μ, ψ_j sú parametre vyhovujúce

$$\sum_{j=-\infty}^{\infty} |\psi_j| < \infty.$$



Lineárne procesy

$$X_t = \mu + \sum_{j=-\infty}^{\infty} \psi_j W_{t-j} \quad |$$

Príklady:

- Biely šum $\psi_0 = 1$
- MA(1) $\psi_0 = 1, \psi_1 = \theta$
- AR(1) $\psi_0 = 1, \psi_1 = \phi, \psi_2 = \phi^2, \dots$



Odhad ACF: výberová ACF

- Pripomeňme si $\{X_t\}$ je stacionárny časový rad:

- Stredná hodnota $\mu = E[X_t]$

- Autokovariančná funkcia $\gamma(h) = \text{Cov}(X_{t+h}, X_t)$
 $= E[(X_{t+h} - \mu)(X_t - \mu)]$

- Autokorelačná funkcia $\rho(h) = \frac{\gamma(h)}{\gamma(0)}$



Odhad ACF: výberová ACF

■ Pre pozorovania x_1, \dots, x_n |

□ Priemer $\bar{x} = \frac{1}{n} \sum_{t=1}^n x_t$ |

□ Výberová autokovariančná funkcia

$$\hat{\gamma}(h) = \frac{1}{n} \sum_{t=1}^{n-|h|} (x_{t+|h|} - \bar{x})(x_t - \bar{x}) \text{ pre } -n < h < n$$

□ Výberová autokorelačná funkcia

$$\hat{\rho}(h) = \frac{\hat{\gamma}(h)}{\hat{\gamma}(0)}$$



Odhad ACF: výberová ACF

Výberové x_1, \dots, x_n | nčná funkcia má tvar

$$\hat{\gamma}(h) = \frac{1}{n} \sum_{t=1}^{n-|h|} (x_{t+|h|} - \bar{x})(x_t - \bar{x})$$

$-n < h < n$

je to podobne tvar ako výberová autokovariancia

$(x_1, x_{h+1}), \dots, (x_{n-h}, x_n)$

Okrem

- Normalizujeme s n namiesto $n-h$
- Odpočítame priemer celého súboru



Výberová ACF

- Ukážeme si výberovú ACF pre rôzne typy časových radov (aj nestacionárnych, ktoré nie sú biely šumom)

Typ časového radu


- Biely šum
- Trend
- Periodický
- MA(q)
- AR(p)

ACF

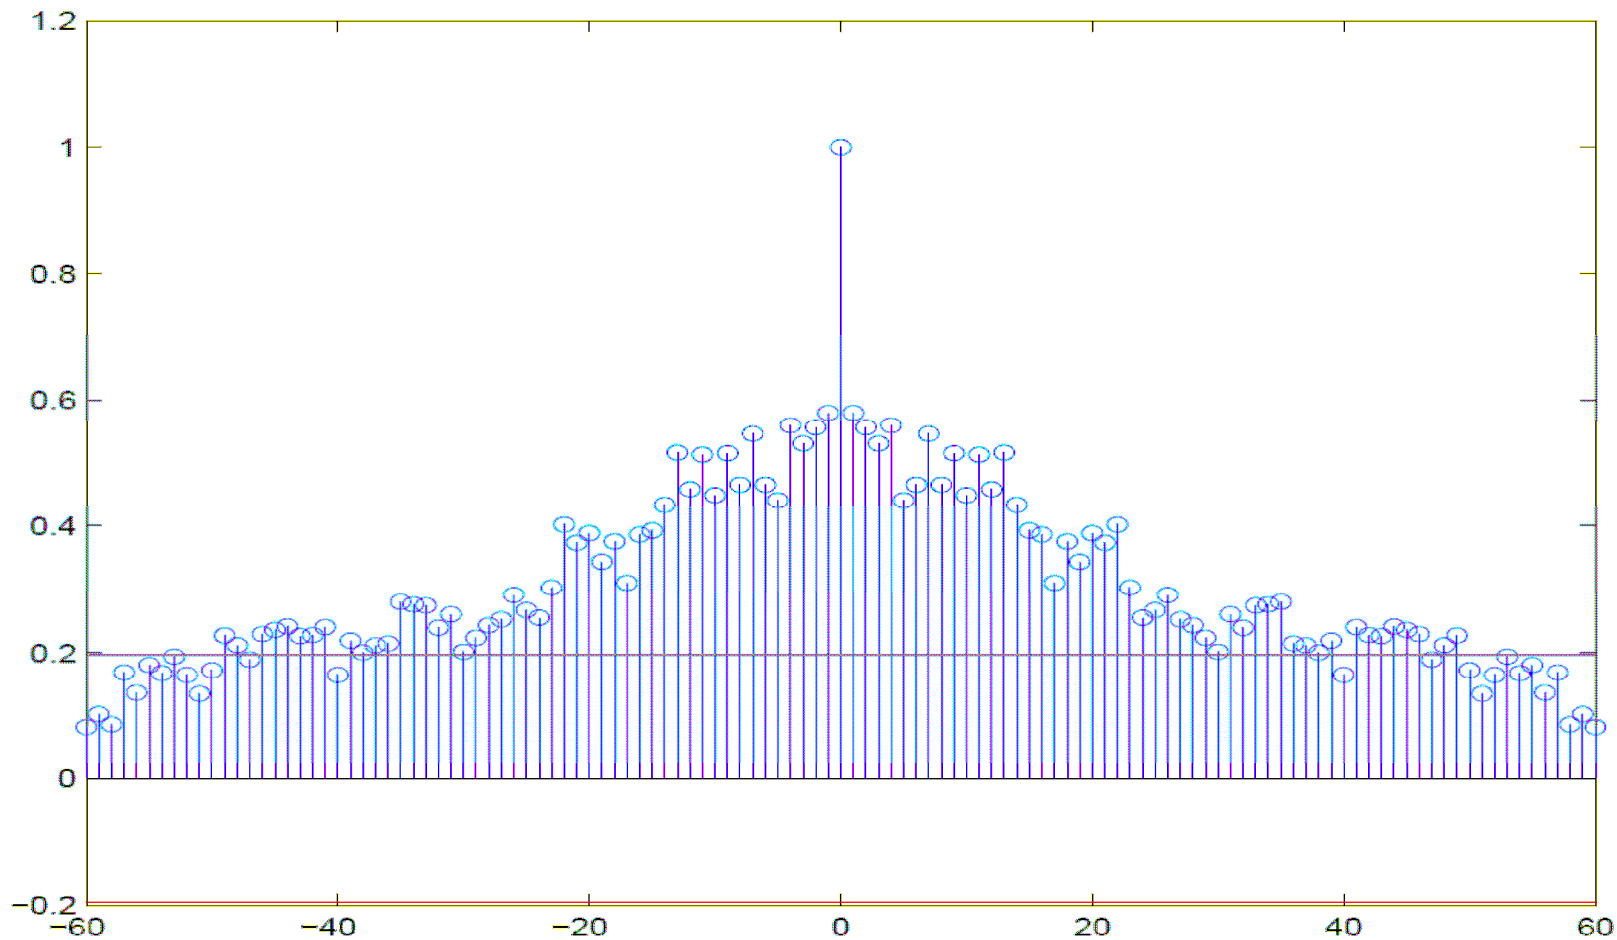
nulová
pomalý pokles
periodická
nulová pre $|h| > q$
exponenciálny pokles



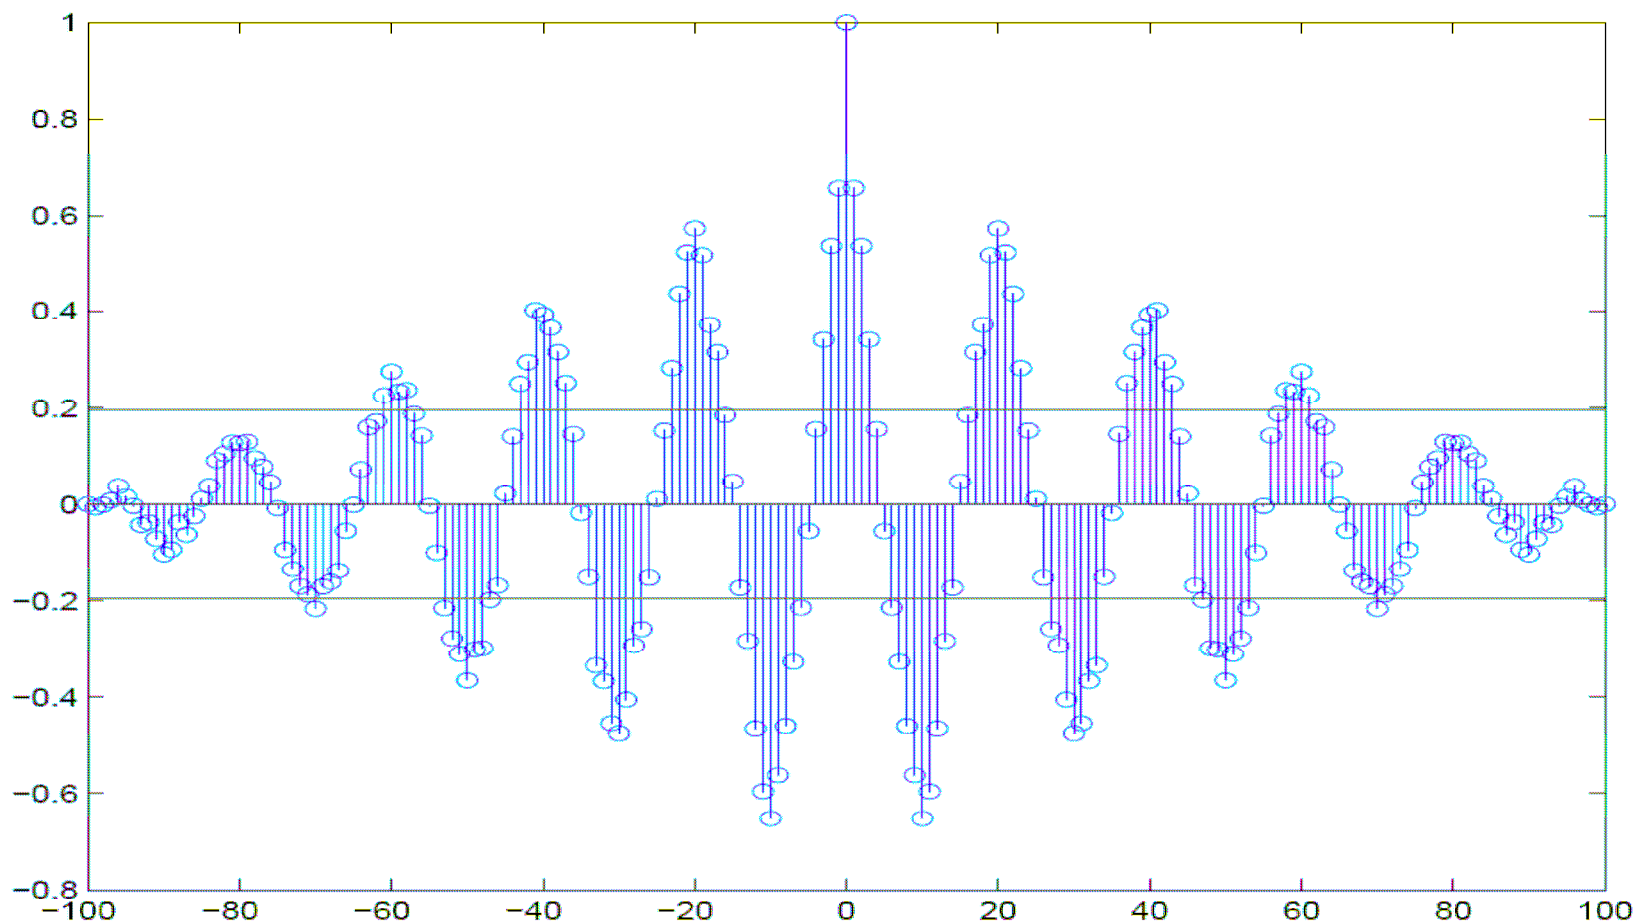
Výberová ACF pre biely gaussovský šum




Výberová ACF - trend




Výberová ACF - periodická



Výberová ACF – MA(1)



Výberová ACF – AR(1)



ACF a predikcia najmenšími štvorcami

- Najlepším odhadom Y najmenšími štvorcami je EY :

$$\min_c E(Y - c)^2 = E(Y - EY)^2$$

- Najlepším odhadom Y za predpokladu X najmenšími štvorcami je $E[Y|X]$:

$$\begin{aligned} \min_f E(Y - f(X))^2 &= \min_f E [E[(Y - f(X))^2|X]] \\ &= E [E[(Y - E[Y|X])^2|X]] \\ &= \text{var}[Y|X]. \end{aligned}$$



ACF a predikcia najmenšími štvorcami

- Podobne, najlepším odhadom X_{n+h} za predpokladu X_n najmenšími štvorcami je EY :

$$f(X_n) = E[X_{n+h}|X_n]$$



ACF a predikcia najmenšími štvorcami

■ Predpokladajme, že $X = (X_1, \dots, X_{n+h})$ je združenou gausovskou náh.premennou

$$f_X(x) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(x - \mu)' \Sigma^{-1} (x - \mu)\right)$$

Potom združenou distribúciou (X_n, X_{n+h}) je

$$N\left(\begin{pmatrix} \mu_n \\ \mu_{n+h} \end{pmatrix}, \begin{pmatrix} \sigma_n^2 & \rho\sigma_n\sigma_{n+h} \\ \rho\sigma_n\sigma_{n+h} & \sigma_{n+h}^2 \end{pmatrix}\right)$$



ACF a predikcia najmenšími štvorcami

■ Predpokladajme, že $X = (X_1, \dots, X_{n+h})$ je združenou gausovskou náh.premennou

$$f_X(x) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp \left(-\frac{1}{2} (x - \mu)' \Sigma^{-1} (x - \mu) \right)$$

Potom podmienenou distribúciou X_{n+h} za podmienky X_n je

$$N \left(\mu_{n+h} + \rho \frac{\sigma_{n+h}}{\sigma_n} (x_n - \mu_n), \sigma_{n+h}^2 (1 - \rho^2) \right)$$



ACF a predikcia najmenšími štvorcami

- Takže pre gausovský a stacionárny rad $\{X_t\}$, najlepším odhadom X_{n+h} za podmienky $X_n = x_n$ je

$$f(x_n) = \mu + \rho(h)(x_n - \mu)$$

a chyba najmenších štvorcov je

$$E(X_{n+h} - f(X_n))^2 = \sigma^2(1 - \rho(h)^2)$$



ACF a predikcia najmenšími štvorcami

■ Poznámky:

- Presnosť predikcie sa zvyšuje, ak

$$|\rho(h)| \rightarrow 1$$

- Predikcia je lineárna

$$f(x) = \mu(1 - \rho(h)) + \rho(h)x$$



ACF a predikcia najmenšími štvorcami

- Uvažujme lineárny prediktor X_{n+h} za podmienky $X_n = x_n$ v tvare

$$f(x_n) = a(x_n - \mu) + b$$

- Pre stacionárny časový rad $\{X_t\}$ najlepší lineárny prediktor minimalizuje

$$\begin{aligned} E (X_{n+h} - (a(X_n - \mu) + b))^2 &= \\ &= E (X_{n+h} - (a(X_n - \mu) + b))^2 \\ &= \sigma^2 + \mu^2 + a^2\sigma^2 + b^2 - 2a\rho(h)\sigma^2 - 2b\mu \end{aligned}$$



ACF a predikcia najmenšími štvorcami

- Tento výraz je minimálny pre

$$a = \rho(h) \quad \text{a} \quad b = \mu$$

- takže

$$f(x_n) = \rho(h)(X_n - \mu) + \mu$$

- Tento optimálny lineárny prediktor má chybu najmenších štvorcov

$$E(X_{n+h} - f(X_n))^2 = \sigma^2(1 - \rho(h)^2)$$



Predikcia X_{n+h} za podmienky X_n najmenšími štvorcami

$$f(x_n) = \rho(h)(X_n - \mu) + \mu$$
$$E(X_{n+h} - f(X_n))^2 = \sigma^2(1 - \rho(h)^2)$$

- Ak $\{X_t\}$ je stacionárny, tak f je optimálny lineárny prediktor
- Ak $\{X_t\}$ je aj gausovský, tak f je optimálny prediktor
- Lineárna predikcia je optimálna pre gaussovské časové rady



Vlastnosti autokovariančnej funkcie

- Autokovariančná funkcia pre $\{X_t\}$ je definovaná ako

$$\begin{aligned}\gamma_X(t+h, t) &= \text{Cov}(X_{t+h}, X_t) \\ &= E[(X_{t+h} - \mu_{t+h})(X_t - \mu_t)]\end{aligned}$$

Ak časový rad je stacionárny, tak môžeme písať

$$\gamma_X(h) = \gamma_X(h, 0)$$



Vlastnosti autokovariančnej funkcie

- Autokovariančná $\gamma|$ funkcia pre stacionárny rad $\{X_t\}$ má tieto vlastnosti
 - 1. $\gamma(0) \geq 0$ - variancia je nezáporná
 - 2. $|\gamma(h)| \leq \gamma(0)$ - Cauchy - Schwarz
 - 3. $\gamma(h) = \gamma(-h)$ - zo stacionarity
 - 4. $\gamma|$ je kladne semidefinitná



Vlastnosti autokovariančnej funkcie

- Funkcia $f : \mathbb{Z} \rightarrow \mathbb{R}$ je kladne semidefinitná, ak pre všetky n je matica F_n s prvkami $(F_n)_{i,j} = f(i - j)$ kladne semidefinitná.
- Matica $F_n \in \mathbb{R}^{n \times n}$ je kladne semidefinitná, ak pre všetky vektory $a \in \mathbb{R}^n$ platí

$$a' F a \geq 0$$



Vlastnosti autokovariančnej funkcie

■ Úloha:

Ukážte, že $\gamma|$ je kladne semidefinitná.

Návod:

Uvažujte varianciu $(X_1, \dots, X_n)a|$



Vlastnosti výberovej autokovariančnej funkcie

- Výberová autokovariančná funkcia má

tvar
$$\hat{\gamma}(h) = \frac{1}{n} \sum_{t=1}^{n-|h|} (x_{t+|h|} - \bar{x})(x_t - \bar{x}) \quad -n < h < n$$

Pre ľubovoľnú postupnosť x_1, \dots, x_n ,
výberová autokovariančná funkcia $\hat{\gamma}$
vyhovuje týmto vlastnostiam:

- $\hat{\gamma}(h) = \hat{\gamma}(-h)$
- $\hat{\gamma}$ je kladne semidefinitná
- $\hat{\gamma}(0) \geq 0$ a $|\hat{\gamma}(h)| \leq \hat{\gamma}(0)$



Odhad μ

■ Pre stacionárny proces $\{X_t\}$, výberový priemer $\bar{X}_n = \frac{1}{n} (X_1 + \dots + X_n)$ vyhovuje

□ $E(\bar{X}_n) = \mu$

□ $\text{var}(\bar{X}_n) = \frac{1}{n} \sum_{h=-n}^n \left(1 - \frac{|h|}{n}\right) \gamma(h)$

□ $\gamma(h) \rightarrow 0 \Rightarrow \text{var}(\bar{X}_n) \rightarrow 0$

□ $\sum_h |\gamma(h)| < \infty \Rightarrow n \text{var}(\bar{X}_n) \rightarrow \sum_{h=-\infty}^{\infty} \gamma(h)$



Odhad ACF: výberová ACF

$$\begin{aligned}\text{var}(\bar{X}_n) &= \mathbf{E} \left(\frac{1}{n} \sum_{i=1}^n X_i - \mu \right) \left(\frac{1}{n} \sum_{j=1}^n X_j - \mu \right) \\ &= \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \mathbf{E}(X_i - \mu)(X_j - \mu) \\ &= \frac{1}{n^2} \sum_{i,j} \gamma(i - j) \\ &= \frac{1}{n} \sum_{h=-(n-1)}^{n-1} \left(1 - \frac{|h|}{n} \right) \gamma(h).\end{aligned}$$



Odhad ACF: výberová ACF

■ Veta

Nech $X_t = \mu + \sum_j \psi_j W_{t-j}$ je taký lineárny proces, že $\sum \psi_j \neq 0$. Potom

$$\bar{X}_n \sim AN \left(\mu_x, \frac{V}{n} \right)$$

kde

$$V = \sum_{h=-\infty}^{\infty} \gamma(h) = \sigma_w^2 \left(\sum_{j=-\infty}^{\infty} \psi_j \right)^2$$



Odhad ACF: výberová ACF

■ Náčrt dôkazu

Pre lineárny proces $X_t = \mu + \sum_j \psi_j W_{t-j}$
máme

$$\gamma_X(h) = \sigma_w^2 \sum_{j=-\infty}^{\infty} \psi_j \psi_{h+j}$$

takže

$$\begin{aligned} \lim_{n \rightarrow \infty} n \operatorname{var}(\bar{X}_n) &= \lim_{n \rightarrow \infty} \sum_{h=-(n-1)}^{n-1} \left(1 - \frac{|h|}{n}\right) \gamma(h) \\ &= \lim_{n \rightarrow \infty} \sigma_w^2 \sum_{j=-\infty}^{\infty} \psi_j \sum_{h=-(n-1)}^{n-1} \left(\psi_{j+h} - \frac{|h|}{n} \psi_{j+h}\right) \\ &= \sigma_w^2 \left(\sum_{j=-\infty}^{\infty} \psi_j \right)^2. \end{aligned}$$



Odhad ACF: výberová ACF

■ Veta

Nech $X_t = \mu + \sum_j \psi_j W_{t-j}$ je taký lineárny proces, že $E(W_t^4) < \infty$. Potom

$$\begin{pmatrix} \hat{\rho}(1) \\ \vdots \\ \hat{\rho}(K) \end{pmatrix} \sim AN \left(\begin{pmatrix} \rho(1) \\ \vdots \\ \rho(K) \end{pmatrix}, \frac{1}{n} V \right)$$

kde

$$V_{i,j} = \sum_{h=1}^{\infty} (\rho(h+i) + \rho(h-i) - 2\rho(i)\rho(h)) \times (\rho(h+j) + \rho(h-j) - 2\rho(j)\rho(h))$$



Odhad ACF: výberová ACF

■ Poznámka

Ak $\rho(i) = 0$ | , tak $V = I$ pre všetky $i \neq 0$ |



Výberová ACF a testovanie bieleho šumu


- Ak $\{X_t\}$ je biely šum, tak očakávame, že nie viac ako $\sim 5\%$ vrcholov výberovej ACF vyhovuje nerovnosti

$$|\hat{\rho}(h)| > \frac{1.96}{\sqrt{n}}$$

Toto je užitočná úvaha, lebo často chceme previesť časový rad na biely šum.



Výberová ACF pre gaussovský biely šum



Výberová ACF pre MA(1)

■ Máme $\rho(0) = 1$, $\rho(\pm 1) = \frac{\theta}{1+\theta^2}$ a $\rho(h) = 0$ pre $|h| > 1$. Teda

$$\begin{aligned} V_{1,1} &= \sum_{h=1}^{\infty} (\rho(h+1) + \rho(h-1) - 2\rho(1)\rho(h))^2 \\ &= (\rho(0) - 2\rho(1)^2)^2 + \rho(1)^2 \end{aligned}$$

$$V_{2,2} = \sum_{h=1}^{\infty} (\rho(h+2) + \rho(h-2) - 2\rho(2)\rho(h))^2 = \sum_{h=-1}^1 \rho(h)^2$$




Výberová ACF pre MA(1)

- Ak $\{X_t\}$ je realizácia takéhoto procesu MA(1), tak s pravdepodobnosťou 0,95 platí

$$|\hat{\rho}(h) - \rho(h)| \leq 1.96 \sqrt{\frac{V_{hh}}{n}}$$



Výberová ACF pre MA(1)



Konvergenca v najmenších štvorcach

- Postupnosť náhodných premenných S_1, S_2, \dots konverguje v najmenších štvorcach, ak existuje taká náhodná premenná Y , pre ktorú

$$\lim_{n \rightarrow \infty} E(S_n - Y)^2 = 0$$

- Rieszova-Fisherova veta (Cauchyho kritérium): S_n konverguje v najmenších štvorcach vtedy a len vtedy, ak

$$\lim_{m, n \rightarrow \infty} E(S_m - S_n)^2 = 0$$



Príklad: lineárny proces

- Uvažujeme lineárny proces

$$X_t = \psi(B)W_t$$

kde

$$\psi(B) = \sum_{j=-\infty}^{\infty} \psi_j B^j$$

Potom, ak platí $\sum_{j=-\infty}^{\infty} |\psi_j| < \infty$

tak

- (1) $|X_t| < \infty$

- (2) $\sum_{j=-\infty}^{\infty} \psi_j W_{t-j}$ konverguje v najm. štvorcach



Príklad: lineárny proces

■ (1)

$$P(|X_t| \geq \alpha) \leq \frac{1}{\alpha} \mathbf{E}|X_t| \quad \text{Markovova nerovnosť}$$

$$\leq \frac{1}{\alpha} \sum_{j=-\infty}^{\infty} |\psi_j| \mathbf{E}|W_{t-j}|$$

$$\leq \frac{\sigma}{\alpha} \sum_{j=-\infty}^{\infty} |\psi_j| \quad \text{Jensenova nerovnosť}$$

$$< \infty$$



Príklad: lineárny proces

■ (2)
Pretože

$$\begin{aligned} E(S_m - S_n)^2 &= E \left(\sum_{m \leq |j| \leq n} \psi_j W_{t-j} \right)^2 \\ &= \sum_{m \leq |j| \leq n} \psi_j^2 \sigma^2 \\ &\leq \sigma^2 \left(\sum_{m \leq |j| \leq n} |\psi_j| \right)^2 \\ &\rightarrow 0. \end{aligned}$$

$$S_n = \sum_{j=-n}^n \psi_j W_{t-j} \text{ konverguje v najm. štvorcach}$$



Príklad: AR(1)

- Nech $\{X_t\}$ je stacionárnym riešením

$$X_t - \phi X_{t-1} = W_t$$

kde $W_t \sim WN(0, \sigma^2)$. Ak $|\phi| < 1$, tak

$$X_t = \sum_{j=0}^{\infty} \phi^j W_{t-j}$$

je riešením. Podobne, vieme ukázať, že suma konverguje v najmenších štvorcoch, pretože $|\phi| < 1$ implikuje $\sum |\phi^j| < \infty$



Príklad: AR(1)

- Navyše, $\{X_t\}$ je jediným stacionárnym riešením: každé iné stacionárne riešenie $\{Y_t\}$ je limitou najmenších štvorcov

$$\begin{aligned} \lim_{n \rightarrow \infty} E \left(Y_t - \sum_{i=0}^{n-1} \phi^i W_{t-i} \right)^2 &= \\ &= \lim_{n \rightarrow \infty} E(\phi^n Y_{t-n})^2 = 0 \end{aligned}$$



Príklad: AR(1)

■ Ekvivalentne, ak napíšeme

$$\pi(B) = \sum_{j=0}^{\infty} \phi^j B^j \quad \Bigg| \quad \phi(B) = 1 - \phi B.$$

Tak môžeme overiť, že $\pi(B) = \phi(B)^{-1}$:

$$\begin{aligned} \pi(B)\phi(B) &= \sum_{j=0}^{\infty} \phi^j B^j (1 - \phi B) = \\ &= \sum_{j=0}^{\infty} \phi^j B^j - \sum_{j=1}^{\infty} \phi^j B^j = 1. \end{aligned}$$



Príklad: AR(1)

■ Teda, z

$$\phi(B)X_t = W_t$$

vyplýva

$$\pi(B)\phi(B)X_t = \pi(B)W_t$$

čo je ekvivalentné

$$X_t = \pi(B)W_t$$



Príklad: AR(1)

■ Poznámka:

Ak

$$|\phi| < 1 \quad \text{a} \quad |z| \leq 1$$

tak

$$\frac{1}{1 - \phi z} = 1 + \phi z + \phi^2 z^2 + \phi^3 z^3 + \dots$$



Príklad: AR(1)

- Nech $\{X_t\}$ je stacionárnym riešením

$$X_t - \phi X_{t-1} = W_t$$

kde $W_t \sim WN(0, \sigma^2)$. Ak $|\phi| < 1$, tak

$$X_t = \sum_{j=0}^{\infty} \phi^j W_{t-j}$$

Otázka na zamyslenie:

Čo sa stane, ak $\phi = 1?$
 $\phi = -1?$
 $|\phi| > 1?$

