

# Časové rady

Ján Pekár  
Prednáška 4

*Lineárna predikcia*

# Predošlá prednáška

---

- Kauzalita
- Invertovateľnosť
- Modely AR(p)
- Modely ARMA(p,q)
- Stacionarita, kauzalita a invertovateľnosť
- Reprezentácia procesov ARMA lineárnymi procesmi
- Autokorelačná a parciálna autokorelačná funkcia procesov ARMA



# Obsah prednášky

---

- PACF
- Rekurzívne metódy: Durbin-Levinson
- Rerezentácia inovácií
- Rekurzívne metódy: Algoritmus inovácií
- Príklad: Algoritmus inovácií pre predpoveď pomocou MA(1)



# Opakovanie: Kauzalita

- Definícia. Lineárny proces  $\{X_t\}$  je kauzálny (presnejšie povedané, je kauzálnou funkciou  $\{W_t\}$ ), ak existuje taký operátor

$$\psi(B) = \psi_0 + \psi_1 B + \psi_2 B^2 + \dots$$

s

$$\sum_{j=0}^{\infty} |\psi_j| < \infty$$

a

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



# Opakovanie: Invertovateľnosť

- Lineárny proces  $\{X_t\}$  je invertovateľný (presnejšie povedané, je invertovateľnou funkciou  $\{W_t\}$ ), ak existuje

$$\pi(B) = \pi_0 + \pi_1 B + \pi_2 B^2 + \dots$$

s

$$\sum_{j=0}^{\infty} |\pi_j| < \infty$$

a

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



# Opakovanie: AR(p) - Autoregresívne modely rádu p

- Definícia. Proces AR(p) (časového radu  $\{X_t\}$ ) je taký stacionárny proces, ktorý spĺňa

$$X_t - \phi_1 X_{t-1} - \dots - \phi_p X_{t-p} = W_t$$

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

Ekvivalentne  $\phi(B)X_t = W_t$

kde  $\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$



# Opakovanie: AR(p) - Stacionarita a kauzalita

- Veta. (Jediné) stacionárne riešenie

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

existuje vtedy a len vtedy, ak

$$|z| = 1 \Rightarrow \phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p \neq 0$$

Tento AR(p) proces je kauzálny vtedy a len vtedy, ak

$$|z| \leq 1 \Rightarrow \phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p \neq 0$$



# Opakovanie: ARMA(p,q)

- Definícia. Proces ARMA(p,q) (časového radu  $\{X_t\}$ ) je taký stacionárny proces, ktorý spĺňa

$$X_t - \phi_1 X_{t-1} - \dots - \phi_p X_{t-p} = W_t + \theta_1 W_{t-1} + \dots + \theta_q W_{t-q}$$

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

- AR(p)=ARMA(p,0):  $\theta(B) = 1$
- MA(q)=ARMA(0,q):  $\phi(B) = 1$





## Opakovanie: Procesy ARMA(p,q)

---

- Veta. Pre ľubovoľný stacionárny proces s autokovarianciou  $\gamma$  a pre každé  $k > 0$ , existuje taký proces ARMA časového radu  $\{X_t\}$ , pre ktorý

$$\gamma_X(h) = \gamma(h), \quad h = 0, 1, \dots, k$$



# Opakovanie: ARMA(p,q) – Stacionarita a kauzalita

- Veta. Ak  $\Phi$  a  $\Theta$  nemajú spoločné korene, tak (jediné) stacionárne riešenie  $\phi(B)X_t = \theta(B)W_t$  | existuje vtedy a len vtedy, ak

$$|z| = 1 \Rightarrow \phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p \neq 0$$

Tento proces ARMA(p,q) je kauzálny vtedy a len vtedy, ak

$$|z| \leq 1 \Rightarrow \phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p \neq 0$$



# Opakovanie: ARMA(p,q) - invertovateľnosť

- Veta. Ak  $\Phi$  a  $\Theta$  nemajú spoločné korene, tak (jediné) stacionárne riešenie  $\phi(B)X_t = \theta(B)W_t$  existuje vtedy a len vtedy, ak

$$|z| = 1 \Rightarrow \phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p \neq 0$$

Tento proces ARMA(p,q) je invertovateľný vtedy a len vtedy, ak

$$|z| \leq 1 \Rightarrow \theta(z) = 1 + \theta_1 z + \dots + \theta_q z^q \neq 0$$



# Opakovanie: Kauzalita a invertovateľnosť

- Veta. Nech  $\{X_t\}$  je proces ARMA určený

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

Ak  $\theta(z) \neq 0$  pre všetky  $|z| = 1$ , tak existujú také polynómy  $\tilde{\phi}$  a  $\tilde{\theta}$  a biely šum  $\tilde{W}_t$ , že  $\{X_t\}$  vyhovuje

$$\tilde{\phi}(B)X_t = \tilde{\theta}(B)\tilde{W}_t$$

pričom tento proces ARMA je kauzálny a invertovateľný.



# Opakovanie: Výberová PACF

- Pre realizáciu  $x_1, x_2, \dots, x_n$ , časového radu výberová PACF je

$$\hat{\phi}_{00} = 1$$

$$\hat{\phi}_{hh} = \text{posledná zložka } \hat{\phi}_h$$

$$\text{kde } \hat{\phi}_h = \hat{\Gamma}_h^{-1} \hat{\gamma}_h$$



# Opakovanie: Jednokroková dopredná lineárna predikcia

$$X_{n+1}^n = \phi_{n1}X_n + \phi_{n2}X_{n-1} + \cdots + \phi_{nn}X_1$$

$$\Gamma_n \phi_n = \gamma_n,$$

$$P_{n+1}^n = \mathbf{E} (X_{n+1} - X_{n+1}^n)^2 = \gamma(0) - \gamma_n' \Gamma_n^{-1} \gamma_n,$$

$$\Gamma_n = \begin{bmatrix} \gamma(0) & \gamma(1) & \cdots & \gamma(n-1) \\ \gamma(1) & \gamma(0) & & \gamma(n-2) \\ \vdots & & \ddots & \vdots \\ \gamma(n-1) & \gamma(n-2) & \cdots & \gamma(0) \end{bmatrix},$$

$$\phi_n = (\phi_{n1}, \phi_{n2}, \dots, \phi_{nn})', \quad \gamma_n = (\gamma(1), \gamma(2), \dots, \gamma(n))'.$$



# Opakovanie: Predikčný operátor

- Pre náhodné premenné  $Y, Z_1, Z_2, \dots, Z_n$ , definujeme **najlepšiu lineárnu predikciu  $Y$  vzhľadom na  $Z = (Z_1, Z_2, \dots, Z_n)$**  ako operátor  $P(.|Z)$  aplikovaný na  $Y$ :

$$P(Y|Z) = \mu_Y + \phi'(Z - \mu_Z)$$

s

$$\Gamma\phi = \gamma,$$

kde

$$\gamma = \text{Cov}(Y, Z)$$

$$\Gamma = \text{Cov}(Z, Z).$$



# Opakovanie: Vlastnosti predikčný operátor

---

1.  $E(Y - P(Y|Z)) = 0, E((Y - P(Y|Z))Z) = 0.$
2.  $E((Y - P(Y|Z))^2) = \text{Var}(Y) - \phi'\gamma.$
3.  $P(\alpha_1 Y_1 + \alpha_2 Y_2 + \alpha_0 | Z) = \alpha_0 + \alpha_1 P(Y_1 | Z) + \alpha_2 P(Y_2 | Z).$
4.  $P(Z_i | Z) = Z_i.$
5.  $P(Y | Z) = EY$  if  $\gamma = 0.$





# Opakovanie: Parciálna autokorelačná funkcia (PACF)

- Definícia. PACF stacionárneho časového radu  $\{X_t\}$  je

$$\phi_{11} = \text{Corr}(X_1, X_0) = \rho(1)$$

$$\phi_{hh} = \text{Corr}(X_h - X_h^{h-1}, X_0 - X_0^{h-1}) \quad \left| \quad h = 2, 3, \dots \right|$$

- Takto eliminujeme lineárne efekty  $X_1, X_2, \dots, X_{h-1}$ :

$$\dots, X_{-1}, \underline{X_0}, \underbrace{X_1, X_2, \dots, X_{h-1}}, \underline{X_h}, X_{h+1}, \dots \quad \left| \right.$$



# Opakovanie: ACF a PACF

---

■ <i>Model</i>	<i>ACF</i>	<i>PACF</i>
□ MA(q)	nulová pre $ h  > q$	exponenciálny pokles
□ AR(p)	exponenciálny pokles	nulová pre $ h  > p$
□ ARMA(p,q)	exponenciálny pokles	exponenciálny pokles



# Opakovanie: Výberová PACF

■ Kde

$$\hat{\Gamma}_n = \begin{pmatrix} \hat{\gamma}(0) & \hat{\gamma}(1) & \cdots & \hat{\gamma}(n-1) \\ \hat{\gamma}(1) & \hat{\gamma}(0) & \cdots & \hat{\gamma}(n-2) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\gamma}(n-1) & \hat{\gamma}(n-2) & \cdots & \hat{\gamma}(0) \end{pmatrix}$$

je kovariančná matica



# Dôležitosť predikcie $P^n_{n+1}$ : Interval predikcie

$$X_{n+1}^n = \phi_{n1}X_n + \phi_{n2}X_{n-1} + \cdots + \phi_{nn}X_1$$

$$\Gamma_n \phi_n = \gamma_n,$$

$$P_{n+1}^n = E (X_{n+1} - X_{n+1}^n)^2 = \gamma(0) - \gamma'_n \Gamma_n^{-1} \gamma_n$$

Po pozorovaní  $X_1, X_2, \dots, X_n$ ,  
predpovedáme  $X_{n+1}$ . Očakávanou  
kvadratickou chybou našej predikcie je

$$P_{n+1}^n$$



# Dôležitosť predikcie $P_{n+1}^n$ : Interval predikcie

---

Môžeme zostrojiť interval predikcie

$$X_{n+1}^n \pm c_{\alpha/2} \sqrt{P_{n+1}^n}.$$

Pre Gaussovský proces, chyba predikcie má distribúciu  $\mathcal{N}(0, P_{n+1}^n)$  takže  $c_{0.05/2} = 1.96$  dáva 95% interval predikcie.



# Výpočet koeficientov predikcie

$$X_{n+1}^n = \phi_{n1}X_n + \phi_{n2}X_{n-1} + \cdots + \phi_{nn}X_1 \quad |$$

$$\Gamma_n \phi_n = \gamma_n, \quad |$$

$$P_{n+1}^n = E (X_{n+1} - X_{n+1}^n)^2 = \gamma(0) - \gamma_n' \Gamma_n^{-1} \gamma_n \quad |$$

Ako môžeme vypočítať tieto veličiny rekurzívne? T.j. ako vieme pomocou  $\phi_{n-1}$  z  $X_n^{n-1}$  vypočítať  $\phi_n$  z  $X_{n+1}^n$  bez riešenia inej lineárnej sústavy  $\Gamma_n \phi_n = \gamma_n$  ?



# Durbin - Levinson

$$\phi_0 = 0,$$

$$\phi_{00} = 0;$$

$$\phi_1 = \phi_{11},$$

$$\phi_{11} = \frac{\gamma(1)}{\gamma(0)};$$

$$\phi_n = \begin{pmatrix} \phi_{n-1} - \phi_{nn}\tilde{\phi}_{n-1} \\ \phi_{nn} \end{pmatrix}, \quad \phi_{nn} = \frac{\gamma(n) - \phi'_{n-1}\tilde{\gamma}_{n-1}}{\gamma(0) - \phi'_{n-1}\gamma_{n-1}}.$$

$$\phi_n = (\phi_{n1}, \dots, \phi_{nn})'$$

$$\tilde{\phi}_n = (\phi_{nn}, \dots, \phi_{n1})',$$

$$\gamma_n = (\gamma(1), \dots, \gamma(n))'$$

$$\tilde{\gamma}_n = (\gamma(n), \dots, \gamma(1))'.$$



# Durbin – Levinson: Príklad

$$\phi_0 = 0,$$

$$\phi_{00} = 0;$$

$$\phi_1 = \phi_{11},$$

$$\phi_{11} = \frac{\gamma(1)}{\gamma(0)};$$

$$\phi_n = \begin{pmatrix} \phi_{n-1} - \phi_{nn}\tilde{\phi}_{n-1} \\ \phi_{nn} \end{pmatrix}, \quad \phi_{nn} = \frac{\gamma(n) - \phi'_{n-1}\tilde{\gamma}_{n-1}}{\gamma(0) - \phi'_{n-1}\gamma_{n-1}}.$$

Tento algoritmus počíta  $\phi_1, \phi_2, \phi_3, \dots$ , kde

$$X_2^1 = X_1\phi_1, \quad X_3^2 = (X_2, X_1)\phi_2, \quad X_4^3 = (X_3, X_2, X_1)\phi_3, \dots$$





# Durbin – Levinson: Príklad

$$\phi_0 = 0,$$

$$\phi_{00} = 0;$$

$$\phi_1 = \phi_{11},$$

$$\phi_{11} = \frac{\gamma(1)}{\gamma(0)};$$

$$\phi_n = \begin{pmatrix} \phi_{n-1} - \phi_{nn}\tilde{\phi}_{n-1} \\ \phi_{nn} \end{pmatrix}, \quad \phi_{nn} = \frac{\gamma(n) - \phi'_{n-1}\tilde{\gamma}_{n-1}}{\gamma(0) - \phi'_{n-1}\gamma_{n-1}}.$$

$$\phi_1 = \gamma(1)/\gamma(0),$$

$$\phi_2 = \begin{pmatrix} \phi_1 - \phi_{22}\phi_{11} \\ \phi_{22} \end{pmatrix} = \begin{pmatrix} \frac{\gamma(1)}{\gamma(0)} \left( 1 - \frac{\gamma(2) - \gamma(1)}{\gamma(0) - \gamma(1)} \right) \\ \frac{\gamma(2) - \gamma(1)}{\gamma(0) - \gamma(1)} \end{pmatrix},$$



# Durbin – Levinson: Ako to funguje?

---

Jasne:  $\Gamma_1 \phi_1 = \gamma_1.$  |

Predpokladáme:  $\Gamma_{n-1} \phi_{n-1} = \gamma_{n-1}.$  |

Potom  $\Gamma_{n-1} \tilde{\phi}_{n-1} = \tilde{\gamma}_{n-1}$  |



# Durbin – Levinson: Ako to funguje?

a

$$\begin{aligned}\Gamma_n \phi_n &= \begin{pmatrix} \Gamma_{n-1} & \tilde{\gamma}_{n-1} \\ \tilde{\gamma}'_{n-1} & \gamma(0) \end{pmatrix} \begin{pmatrix} \phi_{n-1} - \phi_{nn} \tilde{\phi}_{n-1} \\ \phi_{nn} \end{pmatrix} \\ &= \begin{pmatrix} \gamma_{n-1} \\ \tilde{\gamma}'_{n-1} \phi_{n-1} + \phi_{nn} (\gamma(0) - \tilde{\gamma}'_{n-1} \phi_{n-1}) \end{pmatrix} \\ &= \gamma_n.\end{aligned}$$



# Durbin – Levinson: Chyba v najmenších štvorcoch

$$\begin{aligned}
 P_{n+1}^n &= \gamma(0) - \phi_n' \gamma_n \\
 &= \gamma(0) - \begin{pmatrix} \phi_{n-1} - \phi_{nn} \tilde{\phi}_{n-1}' \\ \phi_{nn} \end{pmatrix}' \begin{pmatrix} \gamma_{n-1} \\ \gamma(n) \end{pmatrix} \\
 &= P_n^{n-1} - \phi_{nn} \left( \gamma(n) - \tilde{\phi}_{n-1}' \gamma_{n-1} \right) \\
 &= P_n^{n-1} - \phi_{nn}^2 \left( \gamma(0) - \phi_{n-1}' \gamma_{n-1} \right) \quad \left| \text{z výrazu pre } \phi_{nn} \right| \\
 &= P_n^{n-1} (1 - \phi_{nn}^2) .
 \end{aligned}$$

t.j. variancia sa redukuje faktorom  $1 - \phi_{nn}^2$



# Reprezentácia inovácií

- Namiesto najlepšieho lineárneho prediktora  $X_{n+1}^n = \phi_{n1}X_n + \phi_{n2}X_{n-1} + \dots + \phi_{nn}X_1$  môžeme písať

$$X_{n+1}^n = \theta_{n1} \underbrace{(X_n - X_n^{n-1})} + \theta_{n2} (X_{n-1} - X_{n-1}^{n-2}) + \dots + \theta_{nn} (X_1 - X_1^0)$$

Označme  $U_n = X_n - X_n^{n-1}$ .

Toto je stále lineárne v  $X_1, X_2, \dots, X_n$ .  
Inovácie sú nekorelované

$$\text{Cov}(X_j - X_j^{j-1}, X_i - X_i^{i-1}) = 0 \quad | \quad i \neq j$$



# Porovnanie reprezentácií

## $U_n$ a $X_n$

- $\{U_t\}$  vytvára dekkorelovanú reprezentáciu  $\{X_t\}$

$$\begin{pmatrix} U_1 \\ U_2 \\ \vdots \\ U_n \end{pmatrix} = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ -\phi_{11} & 1 & & 0 \\ \vdots & & \ddots & \\ -\phi_{n-1,n-1} & -\phi_{n-1,n-2} & \cdots & 1 \end{pmatrix} \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{pmatrix}$$



# Porovnanie reprezentácií

## $U_n$ a $X_n$

- $\{U_t\}$  vytvára dekkorelovanú reprezentáciu  $\{X_t\}$

$$\begin{pmatrix} X_1^0 \\ X_2^1 \\ \vdots \\ X_n^{n-1} \end{pmatrix} = \begin{pmatrix} 0 & 0 & \cdots & 0 \\ \theta_{11} & 0 & & 0 \\ \vdots & & \ddots & \\ \theta_{n-1,n-1} & \theta_{n-1,n-2} & \cdots & 0 \end{pmatrix} \begin{pmatrix} U_1 \\ U_2 \\ \vdots \\ U_n \end{pmatrix}$$



# Algoritmus inovácií

$$X_1^0 = 0, \quad X_{n+1}^n = \sum_{i=1}^n \theta_{ni} (X_{n+1-i} - X_{n+1-i}^{n-i})$$

$$\theta_{n,n-i} = \frac{1}{P_{i+1}^i} \left( \gamma(n-i) - \sum_{j=0}^{i-1} \theta_{i,i-j} \theta_{n,n-j} P_{j+1}^j \right).$$

$$P_1^0 = \gamma(0) \quad P_{n+1}^n = \gamma(0) - \sum_{i=0}^{n-1} \theta_{n,n-i}^2 P_{i+1}^i.$$





# Algoritmus inovácií: príklad

$$\theta_{n,n-i} = \frac{1}{P_{i+1}^i} \left( \gamma(n-i) - \sum_{j=0}^{i-1} \theta_{i,i-j} \theta_{n,n-j} P_{j+1}^j \right).$$

$$P_1^0 = \gamma(0) \quad P_{n+1}^n = \gamma(0) - \sum_{i=0}^{n-1} \theta_{n,n-i}^2 P_{i+1}^i.$$

$$\theta_{1,1} = \gamma(1)/P_1^0, \quad P_2^1 = \gamma(0) - \theta_{1,1}^2 P_1^0$$

$$\theta_{2,2} = \gamma(2)/P_1^0, \quad \theta_{2,1} = (\gamma(1) - \theta_{1,1} \theta_{2,2} P_1^0) / P_2^1,$$

$$P_3^2 = \gamma(0) - (\theta_{2,2}^2 P_1^0 + \theta_{2,1}^2 P_2^1)$$

$$\theta_{3,3}, \quad \theta_{3,2}, \quad \theta_{3,1}, \quad P_4^3, \dots$$



# Predikcia $h$ krokov napred pomocou inovácií

- Reprezentácia inovácií pre jednokrokovú naprednú predikciu je

$$P(X_{n+1}|X_1, \dots, X_n) = \sum_{i=1}^n \theta_{ni} (X_{n+1-i} - X_{n+1-i}^{n-i})$$

Ako vyzerá reprezentácia inovácií pre

$$P(X_{n+h}|X_1, \dots, X_n)?$$

Takto:  $P(X_{n+h}|X_1, \dots, X_{n+h-1})$

pozor, nepozorované predikcie od  $n+1$  do  $n+h-1$  položíme rovné nule!



# Predikcia $h$ krokov napred pomocou inovácií

- Ako vyzerá reprezentácia inovácií pre

$$P(X_{n+h}|X_1, \dots, X_n)?$$

**Fakt:** Pre  $h \geq 1$  a  $1 \leq i \leq n$  máme

$$\text{Cov}(X_{n+h} - P(X_{n+h}|X_1, \dots, X_{n+h-1}), X_i) = 0$$

Teda, najlepšou predikciou  $X_{n+h}$  je najlepšia predikcia jednokrokovej predpovede  $X_{n+h}$



# Predikcia $h$ krokov napred pomocou inovácií

- Ako vyzerá reprezentácia inovácií pre

$$P(X_{n+h}|X_1, \dots, X_n)?$$

**Fakt:** Najlepšou predikciou  $X_{n+1} - X_{n+1}^n$  vzhľadom na  $X_1, X_2, \dots, X_n$  je 0. Podobne pre  $n+2, \dots, n+h-1$ .

- Reprezentácia inovácií má tvar

$$P(X_{n+h}|X_1, \dots, X_n) = \sum_{i=1}^n \theta_{n+h-1, h-1+i} (X_{n+1-i} - X_{n+1-i}^{n-i})$$



# Predikcia $h$ krokov napred pomocou inovácií (detail)

$$\begin{aligned} & P(X_{n+h}|X_1, \dots, X_n) \\ &= P(P(X_{n+h}|X_1, \dots, X_{n+h-1})|X_1, \dots, X_n) \\ &= P\left(\sum_{i=1}^{n+h-1} \theta_{n+h-1,i} (X_{n+h-i} - X_{n+h-i}^{n+h-i-1}) | X_1, \dots, X_n\right) \\ &= \sum_{i=1}^{n+h-1} \theta_{n+h-1,i} P((X_{n+h-i} - X_{n+h-i}^{n+h-i-1}) | X_1, \dots, X_n) \\ &= \sum_{i=h}^{n+h-1} \theta_{n+h-1,i} P((X_{n+h-i} - X_{n+h-i}^{n+h-i-1}) | X_1, \dots, X_n) \\ &= \sum_{i=h}^{n+h-1} \theta_{n+h-1,i} (X_{n+h-i} - X_{n+h-i}^{n+h-i-1}) \end{aligned}$$



# Predikcia $h$ krokov napred pomocou inovácií (detail)

$$P(X_{n+1}|X_1, \dots, X_n) = \sum_{i=1}^n \theta_{ni} (X_{n+1-i} - X_{n+1-i}^{n-i})$$

$$P(X_{n+h}|X_1, \dots, X_n) = \sum_{j=h}^{n+h-1} \theta_{n+h-1,j} (X_{n+h-j} - X_{n+h-j}^{n+h-j-1})$$

$$= \sum_{i=1}^n \theta_{n+h-1, h-1+i} (X_{n+1-i} - X_{n+1-i}^{n-i})$$

$$(j = i + h - 1) |$$



# - chyba v najmenších štvorcoch

■ Reprézentácia inovácií má tvar

$$P(X_{n+h}|X_1, \dots, X_n) = \sum_{i=1}^n \theta_{n+h-1, h-1+i} (X_{n+1-i} - X_{n+1-i}^{n-i})$$



# Predikcia $h$ krokov napred - chyba v najmenších štvorcoch

---

- Z ortogonality prediktorov a chyby máme

$$E((X_{n+h} - P(X_{n+h}|X_1, \dots, X_n)) P(X_{n+h}|X_1, \dots, X_n)) = 0.$$

Teda

$$E(X_{n+h} P(X_{n+h}|X_1, \dots, X_n)) = E(P(X_{n+h}|X_1, \dots, X_n)^2).$$





# Predikcia $h$ krokov napred - chyba v najmenších štvorcoch

---

Chybu v najmenších štvorcoch si teda  
môžeme vyjadriť ako

$$\begin{aligned} P_{n+h}^n &= E (X_{n+h} - P(X_{n+h}|X_1, \dots, X_n))^2 \\ &= \gamma(0) + E (P(X_{n+h}|X_1, \dots, X_n))^2 \\ &\quad - 2E (X_{n+h}P(X_{n+h}|X_1, \dots, X_n)) \\ &= \gamma(0) - E (P(X_{n+h}|X_1, \dots, X_n))^2 . \end{aligned}$$



# Predikcia $h$ krokov napred - chyba v najmenších štvorcoch

Avšak inovácie sú nekorelované, takže

$$\begin{aligned}P_{n+h}^n &= \gamma(0) - \mathbb{E} \left( P(X_{n+h} | X_1, \dots, X_n) \right)^2 \\&= \gamma(0) - \mathbb{E} \left( \sum_{j=h}^{n+h-1} \theta_{n+h-1,j} \left( X_{n+h-j} - X_{n+h-j}^{n+h-j-1} \right) \right)^2 \\&= \gamma(0) - \sum_{j=h}^{n+h-1} \theta_{n+h-1,j}^2 \mathbb{E} \left( X_{n+h-j} - X_{n+h-j}^{n+h-j-1} \right)^2 \\&= \gamma(0) - \sum_{j=h}^{n+h-1} \theta_{n+h-1,j}^2 P_{n+h-j}^{n+h-j-1}.\end{aligned}$$



# Algoritmus inovácií pre MA(1)

- Predpokladajme, že máme pre  $\{X_t\}$  proces MA(1), ktorý vyhovuje

$$X_t = W_t + \theta_1 W_{t-1}$$

Pre dané  $X_1, X_2, \dots, X_n$  chceme vypočítať najlepšiu predpoveď  $X_{n+1}$  využijúc reprezentáciu inovácií.

$$X_1^0 = 0, \quad X_{n+1}^n = \sum_{i=1}^n \theta_{ni} (X_{n+1-i} - X_{n+1-i}^{n-i}).$$



# Algoritmus inovácií pre MA(1)

- Odbočka: Lineárne predikcie sú v tvare

$$X_{n+1}^n = \sum_{i=1}^n \theta_{ni} Z_{n+1-i}$$

pre nekorelované náhodné premenné  $Z_i$ ,  
s nulovou strednou hodnotou.

Špeciálne,  $X_{n+1} = Z_{n+1} + \sum_{i=1}^n \theta_{ni} Z_{n+1-i}$

kde  $Z_{n+1} = X_{n+1} - X_{n+1}^n$  (a všetky  $Z_i$ ) sú  
nekorelované. To naznačuje MA  
reprezentáciu.



# Algoritmus inovácií pre MA(1) - príklad

$$\theta_{n,n-i} = \frac{1}{P_{i+1}^i} \left( \gamma(n-i) - \sum_{j=0}^{i-1} \theta_{i,i-j} \theta_{n,n-j} P_{j+1}^j \right).$$

$$P_1^0 = \gamma(0) \quad P_{n+1}^n = \gamma(0) - \sum_{i=0}^{n-1} \theta_{n,n-i}^2 P_{i+1}^i.$$

- Algoritmus počíta  $P_1^0 = \gamma(0)$ ,  $\theta_{1,1}$  pomocou  $\gamma(1)$  d'alej  $P_2^1$ ,  $\theta_{2,2}$  pomocou  $\gamma(2)$ ,  $\theta_{2,1}$ ;  $P_3^2$ ,  $\theta_{3,3}$  pomocou  $\gamma(3)$ , atď.



# Algoritmus inovácií pre MA(1) - príklad

$$\theta_{n,n-i} = \frac{1}{P_{i+1}^i} \left( \gamma(n-i) - \sum_{j=0}^{i-1} \theta_{i,i-j} \theta_{n,n-j} P_{j+1}^j \right).$$

■ Pre MA(1):  $\gamma(0) = \sigma^2(1 + \theta_1^2)$ ,  $\gamma(1) = \theta_1 \sigma^2$ .

Teda  $\theta_{1,1} = \gamma(1)/P_1^0$ ;  
 $\theta_{2,2} = 0$ ,  $\theta_{2,1} = \gamma(1)/P_2^1$ ;  
 $\theta_{3,3} = \theta_{3,2} = 0$ ;  $\theta_{3,1} = \gamma(1)/P_3^2$ .

Pretože  $\gamma(n-i) \neq 0$  len pre  $i = n - 1$  len  $\theta_{n,1} \neq 0$ .



# Algoritmus inovácií pre MA(1) - príklad

- Pre proces MA(1) pre  $\{X_t\}$  vyhovujúci

$$X_t = W_t + \theta_1 W_{t-1}$$

reprezentácia inovácií najlepšej lineárnej predpovede je

$$X_1^0 = 0, \quad X_{n+1}^n = \theta_{n1} (X_n - X_n^{n-1})$$

Vo všeobecnosti, pre proces MA(q) platí  
pre  $i > q$  :  $\theta_{ni} = 0$



# Algoritmus inovácií pre MA(1) - príklad

- Pre proces MA(1) pre  $\{X_t\}$  máme

$$X_1^0 = 0, \quad X_{n+1}^n = \theta_{n1} (X_n - X_n^{n-1})$$

Toto je konzistentné so zistením, že

$$X_{n+1} = Z_{n+1} + \sum_{i=1}^n \theta_{ni} Z_{n+1-i}$$

kde  $Z_t = X_t - X_t^{t-1}$ ,  $t = 1, \dots, n+1$  sú nekorelované. Skutočne, ako  $n$  rastie, tak  $P_{n+1}^n \rightarrow \text{Var}(W_t) \mid (\text{rekurzia } P_{n+1}^n)$  a

$$\theta_{n1} = \gamma(1) / P_n^{n-1} \rightarrow \theta_1$$





# Opakovanie: AR(p)

- Pre proces AR(p) pre  $\{X_t\}$  vyhovujúci

$$X_t = \sum_{i=1}^p \phi_i X_{t-i} + W_t$$

pre  $n \geq p$  máme

$$X_1^0 = 0, \quad X_{n+1}^n = \sum_{i=1}^p \phi_i X_{n+1-i}$$

Potom

$$X_{n+1} = \sum_{i=1}^p \phi_i X_{n+1-i} + Z_{n+1}$$



# Opakovanie: AR(p)

---

kde

$$Z_{n+1} = X_{n+1} - X_{n+1}^n$$

Durbinov – Levinsonov algoritmus je vhodný pre procesy AR(p)

Algoritmus inovácií je vhodný pre procesy MA(q).



# Predpoved' pomocou ARMA(p,q)

---

- Existuje reprezentácia procesov ARMA(p,q) založená na algoritme inovácií. Predpokladajme, že  $\{X_t\}$  je proces ARMA(p,q) :

$$X_t = \sum_{j=1}^p \phi_j X_{t-j} + W_t + \sum_{j=1}^q \theta_j W_{t-j}$$



# Predpoved' pomocou ARMA(p,q)

---

- Uvažujme transformovaný proces

$$Z_t = \begin{cases} X_t/\sigma & |t = 1, \dots, p| \\ \phi(B)X_t/\sigma & |t > p| \end{cases}$$

Ak  $p > 0,$  tak proces nie je stacionárny.



# Predpoved' pomocou ARMA(p,q)

---

Napriek tomu existuje všeobecnejšia verzia algoritmu inovácií, ktorú môžeme použiť na nestacionárne procesy.



# Predpoved' pomocou ARMA(p,q)

- Nech  $\theta_{n,j}$  sú koeficienty získané pomocou algoritmu inovácií na proces  $Z_j$ . Dostaneme tak reprezentáciu

$$X_{n+1}^n = \begin{cases} \sum_{j=1}^n \theta_{nj} (X_{n+1-j} - X_{n+1-j}^{n-j}) & n < p, \\ \sum_{j=1}^p \phi_j X_{n+1-j} + \sum_{j=1}^q \theta_{nj} (X_{n+1-j} - X_{n+1-j}^{n-j}) & n \geq p \end{cases}$$

Pre kauzálny, invertovateľný  $\{X_t\}$

$$E(X_n - X_n^{n-1} - W_n)^2 \rightarrow 0, \theta_{nj} \rightarrow \theta_j, P_n^{n+1} \rightarrow \sigma^2.$$



# Lineárna predikcia založená na nekonečnej minulosti

- Zatiaľ sme uvažovali lineárne prediktory založené na  $n$  pozorovaných hodnotách časového radu

$$X_{n+m}^n = P(X_{n+m} | X_n, X_{n-1}, \dots, X_1)$$

Čo sa stane, ak máme prístup ku **všetkým** predošlým hodnotám  $X_n, X_{n-1}, X_{n-2}, \dots$ ?



# Lineárna predikcia založená na nekonečnej minulosti

■ Označme

$$\begin{aligned}\tilde{X}_{n+m} &= P(X_{n+m} | X_n, X_{n-1}, \dots) \\ &= \sum_{i=1}^{\infty} \alpha_i X_{n+1-i}.\end{aligned}$$

Z vlastnosti ortogonalnosti optimálneho lineárneho prediktora vyplýva

$$E \left[ (\tilde{X}_{n+m} - X_{n+m}) X_{n+1-i} \right] = 0, \quad i = 1, 2, \dots$$





# Lineárna predikcia založená na nekonečnej minulosti

- Teda, ak  $\{X_t\}$  je stacionárny časový rad s nulovou strednou hodnotou, tak

$$\sum_{j=1}^{\infty} \alpha_j \gamma(i-j) = \gamma(m-1+i), \quad i = 1, 2, \dots$$

- Ak  $\{X_t\}$  je kauzálny, invertovateľný lineárny proces, tak môžeme napísať

$$X_{n+m} = \sum_{j=1}^{\infty} \psi_j W_{n+m-j} + W_{n+m},$$

$$W_{n+m} = \sum_{j=1}^{\infty} \pi_j X_{n+m-j} + X_{n+m}$$



# Lineárna predikcia založená na nekonečnej minulosti

■ V takomto prípade

$$\begin{aligned}\tilde{X}_{n+m} &= P(X_{n+m} | X_n, X_{n-1}, \dots) \\ &= P(W_{n+m} | X_n, \dots) - \sum_{j=1}^{\infty} \pi_j P(X_{n+m-j} | X_n, \dots) \\ &= - \sum_{j=1}^{m-1} \pi_j P(X_{n+m-j} | X_n, \dots) - \sum_{j=m}^{\infty} \pi_j X_{n+m-j}.\end{aligned}$$



# Lineárna predikcia založená na nekonečnej minulosti

$$\tilde{X}_{n+m} = - \sum_{j=1}^{m-1} \pi_j P(X_{n+m-j} | X_n, \dots) - \sum_{j=m}^{\infty} \pi_j X_{n+m-j}$$

Teda

$$\tilde{X}_{n+1} = - \sum_{j=1}^{\infty} \pi_j X_{n+1-j},$$

$$\tilde{X}_{n+2} = -\pi_1 \tilde{X}_{n+1} - \sum_{j=2}^{\infty} \pi_j X_{n+2-j},$$

$$\tilde{X}_{n+3} = -\pi_1 \tilde{X}_{n+2} - \pi_2 \tilde{X}_{n+1} - \sum_{j=3}^{\infty} \pi_j X_{n+3-j}.$$

Invertovateľná (AR( $\infty$ )) reprezentácia dáva  
predpoveď  $\tilde{X}_{n+m}^n$



# Lineárna predikcia založená na nekonečnej minulosti

- Aby sme vypočítali chybu v najmenších štvorcoch, musíme si uvedomiť, že

$$\begin{aligned}\tilde{X}_{n+m} &= P(X_{n+m}|X_n, X_{n-1}, \dots) = \sum_{j=1}^{\infty} \psi_j P(W_{n+m-j}|X_n, X_{n-1}, \dots) \\ &\quad + P(W_{n+m}|X_n, X_{n-1}, \dots) \\ &= \sum_{j=m}^{\infty} \psi_j W_{n+m-j}.\end{aligned}$$

$$\begin{aligned}E(X_{n+m} - P(X_{n+m}|X_n, X_{n-1}, \dots))^2 &= E\left(\sum_{j=0}^{m-1} \psi_j W_{n+m-j}\right)^2 \\ &= \sigma_w^2 \sum_{j=0}^{m-1} \psi_j^2.\end{aligned}$$



# Lineárna predikcia založená na nekonečnej minulosti

- Teda, chyba v najmenších štvorcoch predpovede založenej na nekonečnej minulosti je daná začiatočnými členmi kauzálnej (MA( $\infty$ )) reprezentácie

$$E \left( X_{n+m} - \tilde{X}_{n+m} \right)^2 = \sigma_w^2 \sum_{j=0}^{m-1} \psi_j^2$$

Špeciálne pre  $m=1$  chyba v najmenších štvorcoch je  $\sigma_w^2$



# Nabudúce

---

- Odseknutý prediktor
- Odhad parametrov
- Estimátor maximálnej vierohodnosti
- Yuleho – Walkerov odhad

