

Náhodné procesy II

Zuzana Prášková¹

¹Katedra pravděpodobnosti a matematické statistiky

Univerzita Karlova v Praze

email: praskova@karlin.mff.cuni.cz

23.4.-7.5. 2010



Outline

1 Predikce v časové doméně

Projekce v Hilbertově prostoru

Predikce založená na konečné minulosti

Predikce založená na nekonečné minulosti

2 Predikce ve spektrální doméně

Projekce v Hilbertově prostoru

Definice:

Nechť H je Hilbertův prostor (úplný vektorový prostor se skalárním součinem $\langle \cdot, \cdot \rangle$) a normou $\| \cdot \|$, která je pro každé $x \in H$ definovaná jako $\|x\| = \sqrt{\langle x, x \rangle}$.

Jestliže pro dva prvky $x, y \in H$ platí $\langle x, y \rangle = 0$, říkáme, že tyto prvky jsou navzájem **kolmé (ortogonální)** a značíme $x \perp y$.

Nechť $M \subset H$ je podmnožina H . Říkáme, že prvek $x \in H$ je **kolmý k M** , jestliže je kolmý ke každému prvku M , tj. $\langle x, y \rangle = 0$ pro každé $y \in M$. Stručně píšeme $x \perp M$.

Množina $M^\perp = \{y \in H : y \perp M\}$ se nazývá **ortogonální doplněk množiny M** .

Věta 49:

Nechť H je Hilbertův prostor, $M \subset H$ je jeho libovolná podmnožina. Potom M^\perp je uzavřený podprostor H .

Důkaz:

Nulový prvek patří do M^\perp , neboť $\langle 0, x \rangle = 0$ pro každé $x \in M$.

Linearita skalárního součinu \Rightarrow každá lineární kombinace dvou prvků M^\perp je okrešem M^\perp

Spojitost skalárního součinu \Rightarrow limita posloupnosti prvků M^\perp je okrešem M^\perp . □

Věta 50 (o projekci):

Nechť M je uzavřený podprostor Hilbertova prostoru H . Potom pro každý prvek $x \in H$ existuje jednoznačný rozklad na součet $x = \hat{x} + (x - \hat{x})$, kde $\hat{x} \in M$ a $x - \hat{x} \in M^\perp$. Dále platí

$$\|x - \hat{x}\| = \min_{y \in M} \|x - y\| \quad (1)$$

a

$$\|x\|^2 = \|\hat{x}\|^2 + \|x - \hat{x}\|^2. \quad (2)$$

Důkaz: Rudin (2003), věta 4.11.

Prvku $\hat{x} \in M$ s vlastností (1) říkáme **(ortogonální) projekce** prvku x na podprostor M . Zobrazení P_M , které každému prvku $x \in H$ přiřazuje jeho ortogonální projekci na podprostor M , budeme nazývat **projekční zobrazení**. Zřejmě tedy pro každé $x \in H$

$$x = P_M x + (x - P_M x) = P_M x + (I - P_M) x, \quad (3)$$

kde $P_M x \in M$, $(I - P_M) x \in M^\perp$ a I značí identické zobrazení.

Věta 51:

Nechť H je Hilbertův prostor, P_M projekční zobrazení H do jeho uzavřeného podprostoru M .

- ① Pro každé $x, y \in H$ a libovolné $\alpha, \beta \in \mathbb{C}$ je
$$P_M(\alpha x + \beta y) = \alpha P_M x + \beta P_M y.$$
- ② Jestliže $x \in M$, potom $P_M x = x$.
- ③ Jestliže $x \in M^\perp$, potom $P_M x = 0$.
- ④ Jestliže M_1, M_2 jsou uzavřené podprostory H takové, že $M_1 \subseteq M_2$, potom $P_{M_1} x = P_{M_1}(P_{M_2} x)$ pro každé $x \in H$.
- ⑤ Jestliže x_n, x jsou prvky H takové, že $\|x_n - x\| \rightarrow 0$ pro $n \rightarrow \infty$, potom $\|P_M x_n - P_M x\| \rightarrow 0$.

Důkaz:

1

$$\begin{aligned}\alpha x + \beta y &= \alpha(P_M x + (x - P_M x)) + \beta(P_M y + (y - P_M y)) \\ &= \alpha P_M x + \beta P_M y + \alpha(x - P_M x) + \beta(y - P_M y).\end{aligned}$$

$$\begin{aligned}\alpha P_M x + \beta P_M y &\in M, \quad \alpha(x - P_M x) + \beta(y - P_M y) \in M^\perp \\ \Rightarrow \alpha P_M x + \beta P_M y &= P_M(\alpha x + \beta y).\end{aligned}$$

2 Plyne z jednoznačnosti rozkladu (3).

3 Plyne z jednoznačnosti rozkladu (3).

4 $x = P_{M_2} x + (x - P_{M_2} x)$, $P_{M_2} x \in M_2$, $x - P_{M_2} x \in M_2^\perp$

$$P_{M_1} x = P_{M_1}(P_{M_2} x) + P_{M_1}(x - P_{M_2} x).$$

$$P_{M_1}(P_{M_2} x) \in M_1, \quad M_2^\perp \subseteq M_1^\perp \Rightarrow P_{M_1}(x - P_{M_2} x) = 0.$$

5 Z linearity projekce a z rovnice (2)

$$||P_M x_n - P_M x||^2 = ||P_M(x_n - x)||^2 \leq ||x_n - x||^2.$$

Predikce založená na konečné minulosti

Problém: Uvažujme X_1, \dots, X_n s nulovými středními hodnotami a konečnými druhými momenty. Na základě X_1, \dots, X_n chceme předpovědět veličinu X_{n+h} , kde $h > 0$. Hledáme approximaci X_{n+h} měřitelnou funkcí $g(X_1, \dots, X_n)$ (předpověď), pro kterou výraz

$$\mathbb{E} |X_{n+h} - g(X_1, \dots, X_n)|^2$$

nabývá minimální hodnoty.

Řešením této úlohy je podmíněná střední hodnota

$$g(X_1, \dots, X_n) = \mathbb{E}(X_{n+h}|X_1, \dots, X_n).$$

Je totiž, zavedeme-li značení $(X_1, \dots, X_n)' = \mathbf{X}_n$,

$$\begin{aligned} & E(X_{n+h} - g(\mathbf{X}_n))^2 \\ &= E(X_{n+h} - E(X_{n+h}|\mathbf{X}_n) + E(X_{n+h}|\mathbf{X}_n) - g(\mathbf{X}_n))^2 \\ &= E(X_{n+h} - E(X_{n+h}|\mathbf{X}_n))^2 + E(E(X_{n+h}|\mathbf{X}_n) - g(\mathbf{X}_n))^2 \\ &+ 2E[(X_{n+h} - E(X_{n+h}|\mathbf{X}_n))(E(X_{n+h}|\mathbf{X}_n) - g(\mathbf{X}_n))], \end{aligned}$$

přičemž pro poslední sčítanec platí

$$\begin{aligned} & E[(X_{n+h} - E(X_{n+h}|\mathbf{X}_n)) (E(X_{n+h}|\mathbf{X}_n) - g(\mathbf{X}_n))] \\ &= E[E(X_{n+h} - E(X_{n+h}|\mathbf{X}_n)) (E(X_{n+h}|\mathbf{X}_n) - g(\mathbf{X}_n)) |\mathbf{X}_n] \\ &= E[(E(X_{n+h}|\mathbf{X}_n) - E(X_{n+h}|\mathbf{X}_n)) (E(X_{n+h}|\mathbf{X}_n) - g(\mathbf{X}_n))] = 0. \end{aligned}$$

Je tedy

$$\begin{aligned} & E(X_{n+h} - g(\mathbf{X}_n))^2 \\ &= E(X_{n+h} - E(X_{n+h}|\mathbf{X}_n))^2 + E(E(X_{n+h}|\mathbf{X}_n) - g(\mathbf{X}_n))^2 \\ &\geq E(X_{n+h} - E(X_{n+h}|\mathbf{X}_n))^2 \end{aligned}$$

a rovnost nastane pro $g(\mathbf{X}_n) = E(X_{n+h}|\mathbf{X}_n)$.

Obtížné, omezíme se na lineární approximace

Nejlepší lineární předpověď (predikci) prvku X_{n+h} na základě prvků X_1, \dots, X_n budeme značit $\hat{X}_{n+h}(n)$.

Přímá metoda

Nechť $H := \mathcal{H}\{X_1, \dots, X_n, \dots, X_{n+h}\}$ je Hilbertův prostor generovaný náhodnými veličinami X_1, \dots, X_{n+h} a $H_1^n := \mathcal{H}\{X_1, \dots, X_n\}$ nechť je Hilbertův prostor generovaný náhodnými veličinami X_1, \dots, X_n .

Nejlepší lineární predikce X_{n+h} je prvek

$$\hat{X}_{n+h}(n) = \sum_{j=1}^n c_j X_j \in H_1^n, \quad (4)$$

pro který

$$\mathbb{E}|X_{n+h} - \hat{X}_{n+h}(n)|^2 = \|X_{n+h} - \hat{X}_{n+h}(n)\|^2$$

nabývá minimální hodnoty mezi všemi lineárními kombinacemi X_1, \dots, X_n .

Tedy

$$\widehat{X}_{n+h}(n) = P_{H_1^n}(X_{n+h}) \in H_1^n,$$

$$X_{n+h} - \widehat{X}_{n+h}(n) \perp H_1^n. \quad (5)$$

Z linearity prostoru H_1^n plyne, že podmínka (5) bude splněna právě tehdy, když

$$X_{n+h} - \widehat{X}_{n+h}(n) \perp X_j, \quad j = 1, \dots, n,$$

tj. když

$$E(X_{n+h} - \widehat{X}_{n+h}(n))\bar{X}_j = 0, \quad j = 1, \dots, n.$$

Konstanty c_1, \dots, c_n musí tedy splňovat podmínky

$$E(X_{n+h} - \sum_{k=1}^n c_k X_k)\bar{X}_j = 0, \quad j = 1, \dots, n,$$

neboli

$$EX_{n+h}\bar{X}_j - \sum_{k=1}^n c_k EX_k\bar{X}_j = 0, \quad j = 1, \dots, n. \quad (6)$$

Je-li X_1, \dots, X_{n+h} reálná centrovaná stacionární posloupnost s autokovarianční funkcí R , má soustava (6) tvar

$$\sum_{k=1}^n c_k R(k-j) = R(n+h-j), \quad j = 1, \dots, n, \quad (7)$$

neboli

$$c_1 R(0) + c_2 R(1) + \dots + c_n R(n-1) = R(n+h-1),$$

$$c_1 R(1) + c_2 R(0) + \dots + c_n R(n-2) = R(n+h-2),$$

...

$$c_1 R(n-1) + c_2 R(n-2) + \dots + c_n R(0) = R(h).$$

Maticový zápis (7):

$$\Gamma_n \mathbf{c}_n = \gamma_{nh}$$

kde $\mathbf{c}_n := (c_1, \dots, c_n)', \gamma_{nh} := (R(n+h-1), \dots, R(h))'$ a

$$\Gamma_n := \begin{pmatrix} R(0) & R(1) & \dots & R(n-1) \\ R(1) & R(0) & \dots & R(n-2) \\ \vdots & \vdots & \ddots & \vdots \\ R(n-1) & R(n-2) & \dots & R(0) \end{pmatrix},$$

Pokud existuje Γ_n^{-1} , potom $\mathbf{c}_n = \Gamma_n^{-1} \gamma_{nh}$, tedy

$$\hat{X}_{n+h}(n) = \sum_{j=1}^n c_j X_j = \mathbf{c}'_n \mathbf{X}_n = \gamma'_{nh} \Gamma_n^{-1} \mathbf{X}_n. \quad (8)$$

Je zřejmé, že $\Gamma_n = \text{var}(X_1, \dots, X_n) = \text{var } \mathbf{X}_n = E(\mathbf{X}_n \mathbf{X}'_n)$.

Chyba predikce (reziduální rozptyl)

$$\delta_h^2 := E|X_{n+h} - \hat{X}_{n+h}(n)|^2 = \|X_{n+h} - \hat{X}_{n+h}(n)\|^2.$$

Podle (2)

$$\|X_{n+h}\|^2 = \|\hat{X}_{n+h}(n)\|^2 + \|X_{n+h} - \hat{X}_{n+h}(n)\|^2,$$

je tedy

$$\delta_h^2 = \|X_{n+h}\|^2 - \|\hat{X}_{n+h}(n)\|^2. \quad (9)$$

Pro reálnou centrovanou stacionární posloupnost takovou, že
 Γ_n je regulární, platí

$$\begin{aligned}\delta_h^2 &= \|X_{n+h}\|^2 - \|\hat{X}_{n+h}(n)\|^2 = E|X_{n+h}|^2 - E|\hat{X}_{n+h}(n)|^2 \\ &= R(0) - E(\mathbf{c}'_n \mathbf{X}_n)^2 = R(0) - \mathbf{c}'_n E(\mathbf{X}_n \mathbf{X}'_n) \mathbf{c}_n \\ &= R(0) - \mathbf{c}'_n \Gamma_n \mathbf{c}_n = R(0) - \gamma'_{nh} \Gamma_n^{-1} \Gamma_n \Gamma_n^{-1} \gamma_{nh} \\ &= R(0) - \gamma'_{nh} \Gamma_n^{-1} \gamma_{nh}. \end{aligned} \tag{10}$$

Věta 52:

Nechť $\{X_t, t \in \mathbb{Z}\}$ je reálná centrovaná stacionární posloupnost s autokovarianční funkcí R , pro kterou je $R(0) > 0$ a $R(k) \rightarrow 0$ pro $k \rightarrow \infty$. Potom matice $\Gamma_n = \text{var}(X_1, \dots, X_n)$ je regulární pro každé $n \in \mathbb{N}$.

Důkaz:

sporem

Nechť Γ_n je pro nějaké $n \in \mathbb{N}$ singulární; potom existuje nenulový vektor $\mathbf{c} = (c_1, \dots, c_n)'$ takový, že $\mathbf{c}'\Gamma_n\mathbf{c} = 0$ a pro $\mathbf{X}_n = (X_1, \dots, X_n)'$ platí $\mathbf{c}'\mathbf{X}_n = 0$ s. j., neboť $E\mathbf{c}'\mathbf{X}_n = 0$ a $\text{var}(\mathbf{c}'\mathbf{X}_n) = \mathbf{c}'\Gamma_n\mathbf{c} = 0$.

Existuje tedy přirozené $1 \leq r < n$ a konstanty a_1, \dots, a_r takové, že Γ_r je regulární a

$$X_{r+1} = \sum_{j=1}^r a_j X_j.$$

Ze stacionarity posloupnosti $\{X_t, t \in \mathbb{Z}\}$ plyne, že

$$\text{var}(X_1, \dots, X_r) = \dots = \text{var}(X_h, \dots, X_{h+r-1}) = \Gamma_r.$$

Odtud pro libovolné $h \geq 1$

$$X_{r+h} = \sum_{j=1}^r a_j X_{j+h-1}.$$

Pro každé $n \geq r + 1$ najdeme konstanty $a_1^{(n)}, \dots, a_r^{(n)}$ takové, že $X_n = \sum_{j=1}^r a_j^{(n)} X_j = \mathbf{a}^{(n)'} \mathbf{X}_r$, kde $\mathbf{a}^{(n)} = (a_1^{(n)}, \dots, a_r^{(n)})'$ a $\mathbf{X}_r = (X_1, \dots, X_r)'$,

$$\text{var } X_n = \mathbf{a}^{(n)'} \text{var } \mathbf{X}_r \mathbf{a}^{(n)} = \mathbf{a}^{(n)'} \Gamma_r \mathbf{a}^{(n)} = R(0) > 0.$$

Matice Γ_r je pozitivně definitní, tedy existuje rozklad $\Gamma_r = \mathbf{P}\Lambda\mathbf{P}'$, kde Λ je diagonální matice, která má na diagonále vlastní čísla matice Γ_r , a $\mathbf{P}\mathbf{P}' = \mathbf{I}$ je jednotková matice. Protože Γ_r je pozitivně definitní, jsou všechna její vlastní čísla kladná; bez újmy na obecnosti předpokládejme, že $0 < \lambda_1 \leq \dots \leq \lambda_r$. Potom

$$R(0) = \mathbf{a}^{(n)\prime} \mathbf{P} \Lambda \mathbf{P}' \mathbf{a}^{(n)} \geq \lambda_1 \mathbf{a}^{(n)\prime} \mathbf{P} \mathbf{P}' \mathbf{a}^{(n)} = \lambda_1 \sum_{j=1}^r \left(a_j^{(n)} \right)^2,$$

z čehož pro každé $j = 1, \dots, r$ plyne, že $(a_j^{(n)})^2 \leq R(0)/\lambda_1$, tedy $|a_j^{(n)}| \leq C$ nezávisle na n , kde C je kladná konstanta.

Zároveň je

$$\begin{aligned} 0 < R(0) = \mathbb{E}(X_n)^2 &= \mathbb{E}\left(X_n \sum_{j=1}^r a_j^{(n)} X_j\right) = \sum_{j=1}^r a_j^{(n)} \mathbb{E} X_n X_j \\ &= \sum_{j=1}^r a_j^{(n)} R(n-j) \leq \sum_{j=1}^r |a_j^{(n)}| |R(n-j)| \\ &\leq C \sum_{j=1}^r |R(n-j)|. \end{aligned}$$

Poslední výraz s rostoucím n konverguje k nule, neboť podle předpokladu $R(n) \rightarrow 0$ pro $n \rightarrow \infty$, to je ale ve sporu s předpokladem $R(0) > 0$.

Tedy matice Γ_n je regulární pro každé $n \in \mathbb{N}$.



Rekurzivní postupy

Značení:

- $H_1^k = \mathcal{H}\{X_1, \dots, X_k\}$ Hilbertův prostor vytvořený veličinami X_1, \dots, X_k
- $\hat{X}_{k+1}(k) = P_{H_1^k}(X_{k+1}) := \hat{X}_{k+1}, k \geq 1, \hat{X}_1 := 0.$

Potom

$$H_1^n = \mathcal{H}\{X_1, \dots, X_n\} = \mathcal{H}\{X_1 - \hat{X}_1, \dots, X_n - \hat{X}_n\}$$

Lemma:

$X_1 - \hat{X}_1, \dots, X_n - \hat{X}_n$ jsou ortogonální náhodné veličiny.

Důkaz:

Nechť $i < j$. Potom $X_i \in H_1^i \subseteq H_1^{j-1}$ a $\hat{X}_i \in H_1^{i-1} \subset H_1^{j-1}$, tedy $X_i - \hat{X}_i \in H_1^{j-1}$. Dále: $\hat{X}_j = P_{H_1^{j-1}}(X_j)$, proto $X_j - \hat{X}_j \perp H_1^{j-1}$, tedy také

$$X_i - \hat{X}_i \perp X_j - \hat{X}_j.$$

Nejlepší lineární předpověď prvku X_{k+1} spočtená z X_1, \dots, X_k (o jeden krok):

$$\hat{X}_{k+1} = \sum_{j=1}^k \theta_{kj} (X_{k+1-j} - \hat{X}_{k+1-j}).$$

Chyba předpovědi prvku X_{k+1} o jeden krok:

$$v_k = E|X_{k+1} - \hat{X}_{k+1}|^2 = \|X_{k+1} - \hat{X}_{k+1}\|^2, \quad k \geq 0.$$

Věta 53 [Inovační algoritmus]:

Nechť $\{X_t, t \in \mathbb{Z}\}$ je reálná centrovaná posloupnost s autokovarianční funkcí $R(i, j)$, kde matice $(R(i, j))_{i,j=1}^n$ je regulární pro každé n . Potom nejlepší lineární predikce X_{n+1} založená na X_1, \dots, X_n je

$$\hat{X}_1 = 0, \quad (11)$$

$$\hat{X}_{n+1} = \sum_{j=1}^n \theta_{nj} (X_{n+1-j} - \hat{X}_{n+1-j}), \quad n \geq 1, \quad (12)$$

kde pro $k = 0, \dots, n-1$

$$v_0 = R(1, 1), \quad (13)$$

$$\theta_{n,n-k} = \frac{1}{v_k} \left(R(n+1, k+1) - \sum_{j=0}^{k-1} \theta_{k,k-j} \theta_{n,n-j} v_j \right), \quad (14)$$

$$v_n = R(n+1, n+1) - \sum_{j=0}^{n-1} \theta_{n,n-j}^2 v_j. \quad (15)$$

Důkaz:

Definujme $\hat{X}_1 := 0$, potom

$$v_0 = E|X_1 - \hat{X}_1|^2 = E|X_1|^2 = R(1, 1).$$

Víme:

X_{n+1} musí být tvaru (12) a pro $j < k$ jsou $X_j - \hat{X}_j$ a $X_k - \hat{X}_k$ ortogonální. Násobme obě strany (12) skalárně náhodnou veličinou $X_{k+1} - \hat{X}_{k+1}$ pro $k < n$:

$$\begin{aligned} & E\hat{X}_{n+1}(X_{k+1} - \hat{X}_{k+1}) \\ &= \sum_{j=1}^n \theta_{nj} E(X_{n+1-j} - \hat{X}_{n+1-j})(X_{k+1} - \hat{X}_{k+1}) \\ &= \theta_{n,n-k} E(X_{k+1} - \hat{X}_{k+1})^2 = \theta_{n,n-k} v_k. \end{aligned}$$

$\hat{X}_{n+1} \in H_1^n$ a $X_{n+1} - \hat{X}_{n+1} \perp H_1^n \Rightarrow$

$$E(X_{n+1} - \hat{X}_{n+1})(X_{k+1} - \hat{X}_{k+1}) = 0, \quad k < n,$$

$$E X_{n+1}(X_{k+1} - \hat{X}_{k+1}) = E \hat{X}_{n+1}(X_{k+1} - \hat{X}_{k+1}) = \theta_{n,n-k} v_k. \quad (16)$$

Odtud

Zuzana
PráškováPredikce
v časové
doméněProjekce
v Hilbertově
prostoruPredikce
založená na
konečné
minulostiPredikce
založená na
nekonečné
minulostiPredikce ve
spektrální
doméně

$$\begin{aligned}\theta_{n,n-k} &= \frac{1}{v_k} E X_{n+1} (X_{k+1} - \hat{X}_{k+1}) \\ &= \frac{1}{v_k} (R(n+1, k+1) - E X_{n+1} \hat{X}_{k+1}).\end{aligned}$$

Dále, když aplikujeme vzorec (12) na \hat{X}_{k+1} a ve vzorci (16)
místo indexu k užijeme index $k-j$, dostaneme

$$\begin{aligned}E X_{n+1} \hat{X}_{k+1} &= E X_{n+1} \sum_{j=1}^k \theta_{kj} (X_{k+1-j} - \hat{X}_{k+1-j}) \\ &= \sum_{j=1}^k \theta_{kj} E X_{n+1} (X_{k+1-j} - \hat{X}_{k+1-j}) \\ &= \sum_{j=1}^k \theta_{kj} \theta_{n,n-(k-j)} v_{k-j}.\end{aligned}$$

Celkem tedy máme

$$\begin{aligned}\theta_{n,n-k} &= \frac{1}{v_k} \left(R(n+1, k+1) - \sum_{j=1}^k \theta_{kj} \theta_{n,n-(k-j)} v_{k-j} \right) \\ &= \frac{1}{v_k} \left(R(n+1, k+1) - \sum_{\nu=0}^{k-1} \theta_{n,n-\nu} \theta_{k,k-\nu} v_\nu \right).\end{aligned}$$

Výpočet v_n :

$$\begin{aligned} v_n &= E|X_{n+1} - \hat{X}_{n+1}|^2 = E|X_{n+1}|^2 - E|\hat{X}_{n+1}|^2 \\ &= R(n+1, n+1) - E\left|\sum_{j=1}^n \theta_{nj}(X_{n+1-j} - \hat{X}_{n+1-j})\right|^2 \\ &= R(n+1, n+1) - \sum_{j=1}^n \theta_{nj}^2 E(X_{n+1-j} - \hat{X}_{n+1-j})^2 \\ &= R(n+1, n+1) - \sum_{j=1}^n \theta_{nj}^2 v_{n-j} \\ &= R(n+1, n+1) - \sum_{\nu=0}^{n-1} \theta_{n,n-\nu}^2 v_\nu. \end{aligned}$$



Výpočet předpovědi o jeden krok podle inovačního algoritmu
tedy schematicky probíhá takto:

$$\begin{array}{ccccccc} \hat{X}_1 & v_0 & & & & & \\ \theta_{11} & \hat{X}_2 & v_1 & & & & \\ \theta_{22} & \theta_{21} & \hat{X}_3 & v_2 & & & \\ \theta_{33} & \theta_{32} & \theta_{31} & \hat{X}_4 & v_3 & & \\ \dots & & & \dots & & \dots & \end{array}$$

Příklad:

Jsou dány pozorování X_1, \dots, X_n , pro které platí model MA(1),

$$X_t = Y_t + bY_{t-1}, \quad Y_t \sim WN(0, \sigma^2), \quad t \in \mathbb{Z}$$

Určete \hat{X}_{n+1} pomocí inovačního algoritmu.

$$\hat{X}_1 = 0,$$

$$v_0 = R(0) = \sigma^2(1 + b^2),$$

$$\theta_{11} = \frac{1}{v_0} R(1) = \frac{b}{1 + b^2},$$

$$\hat{X}_2 = \theta_{11}(X_1 - \hat{X}_1) = \theta_{11}X_1,$$

$$v_1 = R(0) - \theta_{11}^2 v_0,$$

$$\theta_{22} = \frac{1}{v_0} R(2) = 0,$$

$$\theta_{21} = \frac{1}{v_1}(R(1) - \theta_{22}\theta_{11}v_0) = \frac{R(1)}{v_1},$$

$$\hat{X}_3 = \theta_{21}(X_2 - \hat{X}_2),$$

$$v_2 = R(0) - \theta_{21}^2 v_1,$$

obecně

$$\theta_{nk} = 0, \quad k = 2, \dots, n,$$

$$\theta_{n1} = \frac{R(1)}{v_{n-1}},$$

$$\hat{X}_{n+1} = \theta_{n1}(X_n - \hat{X}_n),$$

$$v_n = R(0) - \theta_{n1}^2 v_{n-1}.$$

Příklad:

Uvažujme model $MA(q)$. Potom je $R(k) = 0$ pro $|k| > q$.
Postupným výpočtem zjistíme, že

$$\hat{X}_{n+1} = \sum_{j=1}^{\min(q,n)} \theta_{nj} (X_{n+1-j} - \hat{X}_{n+1-j}), \quad n \geq 1.$$

Předpověď o $h > 1$ kroků:

$$\widehat{X}_{n+h}(n) = P_{H_1^n}(X_{n+h}), \text{ kde } H_1^n = \mathcal{H}(X_1 - \widehat{X}_1, \dots, X_n - \widehat{X}_n).$$

Protože $H_1^n \subset H_1^{n+1} \subset \dots \subset H_1^{n+h-1}$, plyne z vlastnosti projekčního zobrazení a (12), že

$$\begin{aligned}\widehat{X}_{n+h}(n) &= P_{H_1^n}(X_{n+h}) = P_{H_1^n}\left(P_{H_1^{n+h-1}}(X_{n+h})\right) = P_{H_1^n}(\widehat{X}_{n+h}) \\ &= P_{H_1^n}\left(\sum_{j=1}^{n+h-1} \theta_{n+h-1,j}(X_{n+h-j} - \widehat{X}_{n+h-j})\right) \\ &= \sum_{j=1}^{n+h-1} \theta_{n+h-1,j} P_{H_1^n}(X_{n+h-j} - \widehat{X}_{n+h-j}) \\ &= \sum_{j=h}^{n+h-1} \theta_{n+h-1,j} (X_{n+h-j} - \widehat{X}_{n+h-j}),\end{aligned}\tag{17}$$

neboť $X_{n+h-j} - \widehat{X}_{n+h-j} \perp X_1^n$ pro $j < h$.

Chyba předpovědi o h kroků je

$$\begin{aligned}\delta_h^2 &= \text{E}|X_{n+h} - \hat{X}_{n+h}(n)|^2 = \text{E}|X_{n+h}|^2 - \text{E}|\hat{X}_{n+h}(n)|^2 \\ &= R(n+h, n+h) - \text{E}\left|\sum_{j=h}^{n+h-1} \theta_{n+h-1,j} (X_{n+h-j} - \hat{X}_{n+h-j})\right|^2 \\ &= R(n+h, n+h) - \sum_{j=h}^{n+h-1} \theta_{n+h-1,j}^2 v_{n+h-j-1}.\end{aligned}$$

Příklad:

Uvažujme opět model MA(1).

Již jsme ukázali, že

$$\hat{X}_{n+1} = P_{H_1^n}(X_{n+1}) = \theta_{n1}(X_n - \hat{X}_n).$$

Pro $h > 1$ je

$$\begin{aligned}\hat{X}_{n+h}(n) &= P_{H_1^n}(X_{n+h}) = P_{H_1^n}(\hat{X}_{n+h}) \\ &= P_{H_1^n}(\theta_{n+h-1,1}(X_{n+h-1} - \hat{X}_{n+h-1})) = 0,\end{aligned}$$

neboť $(X_{n+h-1} - \hat{X}_{n+h-1}) \perp H_1^n$ pro $h > 1$.

Inovační algoritmus pro model ARMA

Uvažujme kauzální proces ARMA(p, q)

$$X_t = \varphi_1 X_{t-1} + \cdots + \varphi_p X_{t-p} + Y_t + \theta_1 Y_{t-1} + \cdots + \theta_q Y_{t-q}, \quad t \in \mathbb{Z},$$

$$Y_t \sim \text{WN}(0, \sigma^2). \quad \text{Hledáme } \widehat{X}_{n+1} = P_{H_1^n}(X_{n+1}).$$

Transformace:

$$W_t = \begin{cases} \frac{1}{\sigma} X_t, & t = 1, 2, \dots, m, \\ \frac{1}{\sigma} (X_t - \varphi_1 X_{t-1} - \cdots - \varphi_p X_{t-p}), & t > m, \end{cases} \quad (18)$$

$$m = \max(p, q).$$

Položme $\widehat{X}_1 = 0, \widehat{W}_1 = 0, \widehat{W}_k = P_{H_1^{k-1}}(W_k)$. Potom

$$\begin{aligned} H_1^n &= \mathcal{H}(X_1 - \widehat{X}_1, \dots, X_n - \widehat{X}_n) = \mathcal{H}(X_1, \dots, X_n) \\ &= \mathcal{H}(W_1, \dots, W_n) = \mathcal{H}(W_1 - \widehat{W}_1, \dots, W_n - \widehat{W}_n). \end{aligned}$$

- Aplikace inovačního algoritmu na posloupnost $\{W_1, \dots, W_n\}$:

$$\widehat{W}_{n+1} = \begin{cases} \sum_{j=1}^n \theta_{nj}(W_{n+1-j} - \widehat{W}_{n+1-j}), & 1 \leq n < m, \\ \sum_{j=1}^q \theta_{nj}(W_{n+1-j} - \widehat{W}_{n+1-j}), & n \geq m \end{cases} \quad (19)$$

(pro $t > m$ je $W_t \sim MA(q)$).

- Projekce do H_1^{t-1} na obě strany vztahu (18):

$$\widehat{W}_t = \begin{cases} \frac{1}{\sigma} \widehat{X}_t, & t \leq m, \\ \frac{1}{\sigma} (\widehat{X}_t - \varphi_1 X_{t-1} - \cdots - \varphi_p X_{t-p}), & t > m. \end{cases} \quad (20)$$

Je vidět, že pro $t \geq 1$

$$W_t - \widehat{W}_t = \frac{1}{\sigma} (X_t - \widehat{X}_t), \quad E|W_t - \widehat{W}_t|^2 = \frac{1}{\sigma^2} v_{t-1} := w_{t-1}.$$

Platí tedy

$$\widehat{X}_{n+1} = \begin{cases} \sum_{j=1}^n \theta_{nj} (X_{n+1-j} - \widehat{X}_{n+1-j}), & n < m \\ \sum_{j=1}^q \theta_{nj} (X_{n+1-j} - \widehat{X}_{n+1-j}) + \sum_{j=1}^p \varphi_j X_{n-j+1}, & n \geq m \end{cases} \quad (21)$$

kde koeficienty θ_{nj} a w_n se spočtou inovačním algoritmem aplikovaným na posloupnost (18).

K tomu musíme spočítat hodnoty autokovarianční funkce posloupnosti $\{W_t\}$.

Víme, že $E X_t = 0$, tedy i $E W_t = 0$.

Pro kovariance $R_W(s, t) = E W_s W_t$ platí

$$R_W(s, t) = \begin{cases} \frac{1}{\sigma^2} R_X(s - t), & 1 \leq s, t \leq m, \\ \frac{1}{\sigma^2} [R_X(s - t) - \sum_{j=1}^p \varphi_j R_X(|s - t| - j)], & \min(s, t) \leq m, \quad m < \max(s, t) \leq 2m, \\ \frac{1}{\sigma^2} \sum_{j=0}^{q-|s-t|} \theta_j \theta_{j+|s-t|}, & s, t > m, \quad |s - t| \leq q, \\ 0, & \text{jinde} \end{cases} \quad (22)$$

(zde jsme položili $\theta_0 = 1$).

Inovační algoritmus pro model AR

Uvažujme kauzální proces $AR(p)$, tj.

$$X_t = \varphi_1 X_{t-1} + \cdots + \varphi_p X_{t-p} + Y_t, \quad t \in \mathbb{Z}, \quad Y_t \sim WN(0, \sigma^2)$$

- Transformace:

$$W_t = \begin{cases} \frac{1}{\sigma} X_t, & 1 \leq t \leq p, \\ \frac{1}{\sigma} (X_t - \varphi_1 X_{t-1} - \cdots - \varphi_p X_{t-p}) = \frac{1}{\sigma} Y_t, & t > p. \end{cases} \quad (23)$$

- Inovační algoritmus na W_1, \dots, W_n :

$$\widehat{W}_{n+1} = \begin{cases} \sum_{j=1}^n \theta_{nj} (W_{n+1-j} - \widehat{W}_{n+1-j}), & n < p, \\ 0, & n \geq p. \end{cases} \quad (24)$$

$$(W_{n+1} \perp H_1^n \text{ pro } n \geq p.)$$

Opět $W_t - \widehat{W}_t = \frac{1}{\sigma}(X_t - \widehat{X}_t)$ pro $t \geq 1$ a odtud

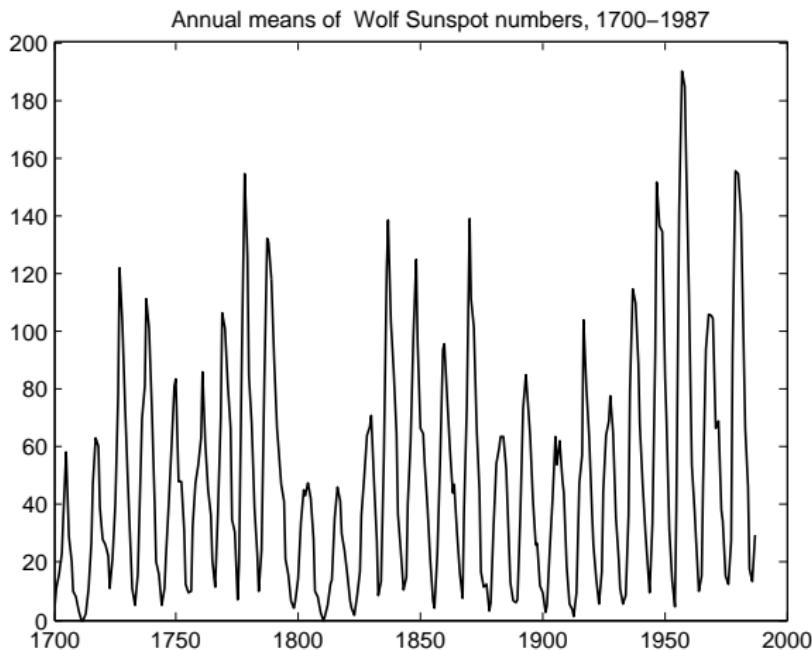
$$\widehat{X}_{n+1} = \begin{cases} \sum_{j=1}^n \theta_{nj}(X_{n+1-j} - \widehat{X}_{n+1-j}), & n < p, \\ \varphi_1 X_n + \varphi_2 X_{n-1} + \cdots + \varphi_p X_{n-p+1}, & n \geq p. \end{cases} \quad (25)$$

Autokovarianční funkce potřebná pro výpočet koeficientů θ_{nj} je

$$R_W(s, t) = \begin{cases} \frac{1}{\sigma^2} R_X(s-t), & 1 \leq s, t \leq p, \\ 1, & t = s > p, \\ 0 & \text{jinde.} \end{cases} \quad (26)$$

Chybu předpovědi o jeden krok pro $n \geq p$ můžeme spočítat jako

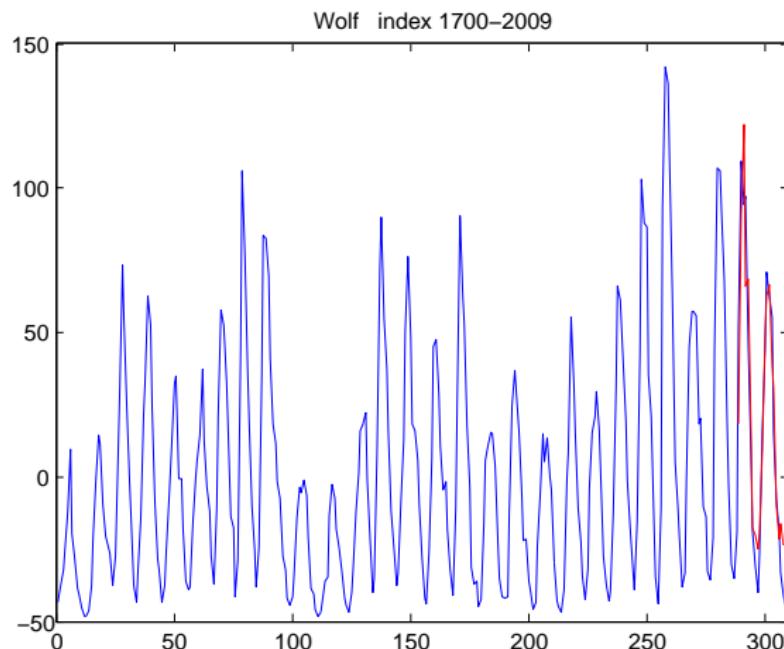
$$v_n = E|X_{n+1} - \widehat{X}_{n+1}|^2 = EY_{n+1}^2 = \sigma^2.$$



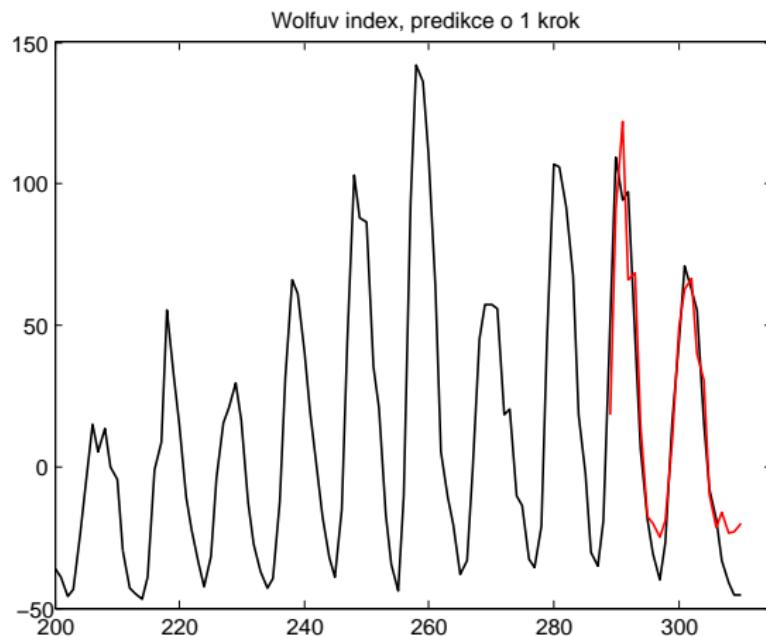
Počet slunečních skvrn, Wolfův index, 1700-1987

Odhadnutý model pro Wolfův index (centrováno):
 $AR(9), a(B)X_t = Y_t$

$$a(z) = 1 - 1.182z + 0.4248z^2 + 0.1619z^3 - 0.1687z^4 \\ + 0.1156z^5 - 0.02689z^6 - 0.005769z^7 \\ + 0.02251z^8 - 0.2062z^9$$



Počet slunečních skvrn, Wolfův index, 1700-2009, skutečné
hodnoty a predikce o jeden krok



Počet slunečních skvrn, Wolfův index, 1700-2009, skutečné a
predikované hodnoty (výřez)

Predikce založená na nekonečné minulosti

Problém: známe celou minulost X_n, X_{n-1}, \dots , chceme předpovídat X_{n+1}, X_{n+2}, \dots .

Úloha projekce v Hilbertově prostoru: Uvažujme Hilbertovy prostory $H = \mathcal{H}\{X_t, t \in \mathbb{Z}\}$ a $H_{-\infty}^n = \mathcal{H}\{\dots, X_{n-1}, X_n\}$.

Předpověď $\hat{X}_{n+h}(n)$ prvku X_{n+h} založená na nekonečné minulosti X_n, X_{n-1}, \dots je projekce $X_{n+h} \in H$ do $H_{-\infty}^n$,

$$\hat{X}_{n+h}(n) = P_{H_{-\infty}^n}(X_{n+h})$$

předpověď o jeden krok: $\hat{X}_{n+1}(n) := \hat{X}_{n+1}$.

Předpověď v autoregresním modelu AR(p).

Uvažujme model

$$X_t = \varphi_1 X_{t-1} + \cdots + \varphi_p X_{t-p} + Y_t, \quad t \in \mathbb{Z}, \quad (27)$$

kde $\{Y_t, t \in \mathbb{Z}\}$ je $WN(0, \sigma^2)$, a předpokládejme, že polynom $\lambda^p - \varphi_1 \lambda^{p-1} - \cdots - \varphi_p$ má všechny kořeny uvnitř jednotkového kruhu.

Víme: $\{X_t, t \in \mathbb{Z}\}$ je kauzální lineární proces a $Y_t \perp X_s$ pro všechna $t > s$.

Předpověď o jeden krok:

- $X_{n+1} = \varphi_1 X_n + \cdots + \varphi_p X_{n+1-p} + Y_{n+1}$
- $\varphi_1 X_n + \cdots + \varphi_p X_{n+1-p} \in H_{-\infty}^n,$
- $Y_{n+1} \perp X_n, X_{n-1}, \dots \Rightarrow Y_{n+1} \perp H_{-\infty}^n,$ (plyne z linearity a spojitosti skalárního součinu)

$$\hat{X}_{n+1} = P_{H_{-\infty}^n}(X_{n+1}) = \varphi_1 X_n + \cdots + \varphi_p X_{n+1-p}.$$

Chyba předpovědi je

$$E|X_{n+1} - \hat{X}_{n+1}|^2 = E|Y_{n+1}|^2 = \sigma^2.$$

Předpověď o $h > 1$ kroků.

$$\begin{aligned}\hat{X}_{n+h}(n) &= P_{H_{-\infty}^n}(X_{n+h}) = P_{H_{-\infty}^n} \left(P_{H_{-\infty}^{n+h-1}}(X_{n+h}) \right) \\ &= P_{H_{-\infty}^n}(\hat{X}_{n+h}) \\ &= P_{H_{-\infty}^n}(\varphi_1 X_{n+h-1} + \cdots + \varphi_p X_{n+h-p}) \\ &= \varphi_1[X_{n+h-1}] + \varphi_2[X_{n+h-2}] + \cdots + \varphi_p[X_{n+h-p}],\end{aligned}$$

kde

$$[X_{n+j}] = \begin{cases} X_{n+j}, & j \leq 0 \\ \hat{X}_{n+j}(n), & j > 0. \end{cases}$$

Příklad:

Uvažujme proces AR(1),

$$X_t = \varphi X_{t-1} + Y_t, \quad |\varphi| < 1, \quad Y_t \sim WN(0, \sigma^2).$$

Známe-li celou minulost X_n, X_{n-1}, \dots , je $\hat{X}_{n+1} = \varphi X_n$.

Pro $h > 1$

$$\begin{aligned}\hat{X}_{n+h}(n) &= \varphi[X_{n+h-1}] = \varphi\hat{X}_{n+h-1}(n) = \varphi^2\hat{X}_{n+h-2}(n) = \dots \\ &= \varphi^h X_n.\end{aligned}$$

Chyba predikce je

$$\begin{aligned}E|X_{n+h} - \hat{X}_{n+h}|^2 &= E|X_{n+h}|^2 - E|\hat{X}_{n+h}(n)|^2 \\ &= R_X(0) - E|\varphi^h X_n|^2 = R_X(0) (1 - \varphi^{2h}) \\ &= \sigma^2 \frac{1 - \varphi^{2h}}{1 - \varphi^2}.\end{aligned}$$

Kauzální a invertibilní model ARMA(p, q)

$$X_t = \varphi_1 X_{t-1} + \cdots + \varphi_p X_{t-p} + Y_t + \theta_1 Y_{t-1} + \cdots + \theta_q Y_{t-q}, \quad t \in \mathbb{Z}, \quad (28)$$

$$Y_t \sim \text{WN}(0, \sigma^2).$$

- Kauzálnita: pro každé $t \in \mathbb{Z}$ je $X_t = \sum_{j=0}^{\infty} c_j Y_{t-j}$, kde $\sum_{j=0}^{\infty} |c_j| < \infty$
odtud plyne, že $Y_t \perp X_s$ pro každé $s < t$.
- Invertibilita: pro každé $t \in \mathbb{Z}$ je $Y_t = \sum_{j=0}^{\infty} d_j X_{t-j}$, kde $\sum_{j=0}^{\infty} |d_j| < \infty$, neboli

$$X_t = - \sum_{j=1}^{\infty} d_j X_{t-j} + Y_t \quad (29)$$

(srov. věty 35 a 36.)

Platí:

$$-\sum_{j=1}^{\infty} d_j X_{t-j} = \text{l. i. m. }_{N \rightarrow \infty} \left(-\sum_{j=1}^N d_j X_{t-j} \right) \in H_{-\infty}^{t-1},$$

$Y_t \perp H_{-\infty}^{t-1}$. Z rozkladu (29) tedy plyne, že nejlepší lineární předpověď X_{n+1} založená na celé minulosti X_n, X_{n-1}, \dots je

$$\hat{X}_{n+1} = -\sum_{j=1}^{\infty} d_j X_{n+1-j}. \quad (30)$$

Chyba předpovědi

$$\mathbb{E}|X_{n+1} - \hat{X}_{n+1}|^2 = \mathbb{E}|Y_{n+1}|^2 = \sigma^2.$$

Rekurentní vyjádření Y_t : $Y_t = X_t - \hat{X}_t$

Z jednoznačnosti rozkladu $X_{n+1} = \hat{X}_{n+1} + Y_{n+1}$ a ze vzorce (28)

$$\hat{X}_{n+1} = \varphi_1 X_n + \cdots + \varphi_p X_{n+1-p} + \theta_1 Y_n + \cdots + \theta_q Y_{n+1-q},$$

tedy

$$\begin{aligned}\hat{X}_{n+1} &= \varphi_1 X_n + \cdots + \varphi_p X_{n+1-p} \\ &\quad + \theta_1 (X_n - \hat{X}_n) + \cdots + \theta_q (X_{n+1-q} - \hat{X}_{n+1-q}).\end{aligned}$$

Predikce o $h > 1$ kroků je

$$\begin{aligned}
 \hat{X}_{n+h}(n) &= P_{H_{-\infty}^n}(X_{n+h}) = P_{H_{-\infty}^n}(P_{H_{-\infty}^{n+h-1}}(X_{n+h})) \\
 &= P_{H_{-\infty}^n}(\hat{X}_{n+h}) \\
 &= P_{H_{-\infty}^n}(\varphi_1 X_{n+h-1} + \cdots + \varphi_p X_{n+h-p} \\
 &\quad + \theta_1 Y_{n+h-1} + \cdots + \theta_q Y_{n+h-q}) \\
 &= \varphi_1 [X_{n+h-1}] + \cdots + \varphi_p [X_{n+h-p}] \\
 &\quad + \theta_1 [Y_{n+h-1}] + \cdots + \theta_q [Y_{n+h-q}],
 \end{aligned}$$

kde

$$[X_{n+j}] = \begin{cases} X_{n+j}, & j \leq 0, \\ \hat{X}_{n+j}(n), & j > 0 \end{cases}$$

a

$$[Y_{n+j}] = \begin{cases} X_{n+j} - \hat{X}_{n+j}, & j \leq 0, \\ 0, & j > 0. \end{cases}$$

Pro výpočet chyby predikce je výhodné využít kauzality.
Dostaneme

$$\hat{X}_{n+h}(n) = P_{H_{-\infty}^n}(X_{n+h}) = P_{H_{-\infty}^n}\left(\sum_{j=0}^{\infty} c_j Y_{n+h-j}\right).$$

Z vlastností projekčního zobrazení

$$P_{H_{-\infty}^n}\left(\sum_{j=0}^{\infty} c_j Y_{n+h-j}\right) = \sum_{j=0}^{\infty} c_j P_{H_{-\infty}^n}(Y_{n+h-j}),$$

a

$$\hat{X}_{n+h}(n) = \sum_{j=h}^{\infty} c_j Y_{n+h-j}.$$

Chyba předpovědi je

$$\text{E}|X_{n+h} - \hat{X}_{n+h}(n)|^2 = \text{E}\left|\sum_{j=0}^{h-1} c_j Y_{n+h-j}\right|^2 = \sigma^2 \sum_{j=0}^{h-1} |c_j|^2.$$

Příklad:

Uvažujme model MA(1):

$$X_t = Y_t + \theta Y_{t-1}, t \in \mathbb{Z}, \quad Y_t \sim WN(0, \sigma^2), \quad |\theta| < 1.$$

Potom $\{X_t, t \in \mathbb{Z}\}$ je invertibilní, $Y_t = \sum_{j=0}^{\infty} (-\theta)^j X_{t-j}$, a

$$\hat{X}_{n+1}(n) = \hat{X}_{n+1} = - \sum_{j=1}^{\infty} (-\theta)^j X_{n+1-j} = \theta Y_n = \theta(X_n - \hat{X}_n).$$

$$\text{Chyba predikce je } E|X_{n+1} - \hat{X}_{n+1}|^2 = EY_{n+1}^2 = \sigma^2.$$

Predikce o $h > 1$ kroků je

$$\begin{aligned} \hat{X}_{n+h}(n) &= P_{H_{-\infty}^n}(P_{H_{-\infty}^{n+h-1}}(X_{n+h})) = P_{H_{-\infty}^n}(\hat{X}_{n+h}) \\ &= \theta P_{H_{-\infty}^n}(Y_{n+h-1}) = 0, \end{aligned}$$

neboť pro $h \geq 2$ je $Y_{n+h-1} \perp H_{-\infty}^n$.

Chyba předpovědi je

$$E|X_{n+h} - \hat{X}_{n+h}(n)|^2 = E|X_{n+h}|^2 = R_X(0) = \sigma^2(1 + \theta^2).$$

Predikce ve spektrální doméně

- $\{X_t, t \in \mathbb{Z}\}$ centrovaná stacionární posloupnost se spektrální distribuční funkcí F a spektrální hustotou f .
- Známe celou minulost posloupnosti $\{X_t, t \in \mathbb{Z}\}$ do času $n - 1$, hledáme předpověď X_{n+h} , $h = 0, 1, \dots$, tj.
 - $\hat{X}_{n+h}(n-1) = P_{H_{-\infty}^{n-1}}(X_{n+h})$,
 - $\hat{X}_{n+h}(n-1) \in H_{-\infty}^{n-1} \subset \mathcal{H}\{X_t, t \in \mathbb{Z}\}$,
 - $X_{n+h} - \hat{X}_{n+h}(n-1) \perp H_{-\infty}^{n-1}$.
- Spektrální rozklad: $X_t = \int_{-\pi}^{\pi} e^{it\lambda} dZ(\lambda)$,
 $\{Z_\lambda, \lambda \in [-\pi, \pi]\}$ je proces s ortogonálními přírůstky a přírůstkovou distribuční funkcí F (věta 28).
- Všechny prvky Hilbertova prostoru $\mathcal{H}\{X_t, t \in \mathbb{Z}\}$ jsou tvaru
$$\int_{-\pi}^{\pi} \varphi(\lambda) dZ(\lambda),$$
kde $\varphi \in L_2(F)$ (věta 30).

Hledejme prvek $\hat{X}_{n+h}(n-1)$ ve tvaru

$$\hat{X}_{n+h}(n-1) = \int_{-\pi}^{\pi} e^{in\lambda} \Phi_h(\lambda) dZ(\lambda), \quad (31)$$

kde $\Phi_h(\lambda) \in L_2(F)$. Podmínka $X_{n+h} - \hat{X}_{n+h}(n-1) \perp H_{-\infty}^{n-1}$
bude splněna, když

$$X_{n+h} - \hat{X}_{n+h}(n-1) \perp X_{n-j}, \quad j = 1, 2, \dots$$

Tedy pro $j = 1, 2, \dots$ musí platit

$$\mathbb{E}(X_{n+h} - \hat{X}_{n+h}(n-1)) \bar{X}_{n-j} = 0,$$

neboli

$$\begin{aligned}
 & E \left(X_{n+h} - \hat{X}_{n+h}(n-1) \right) \bar{X}_{n-j} = \\
 & = R(h+j) - E \int_{-\pi}^{\pi} e^{in\lambda} \Phi_h(\lambda) dZ(\lambda) \overline{\int_{-\pi}^{\pi} e^{i(n-j)\lambda} dZ(\lambda)} \\
 & = R(h+j) - \int_{-\pi}^{\pi} e^{in\lambda} \Phi_h(\lambda) e^{-i(n-j)\lambda} dF(\lambda) \\
 & = \int_{-\pi}^{\pi} e^{i(h+j)\lambda} dF(\lambda) - \int_{-\pi}^{\pi} e^{ij\lambda} \Phi_h(\lambda) dF(\lambda) \\
 & = \int_{-\pi}^{\pi} e^{i(h+j)\lambda} f(\lambda) d\lambda - \int_{-\pi}^{\pi} e^{ij\lambda} \Phi_h(\lambda) f(\lambda) d\lambda \\
 & = \int_{-\pi}^{\pi} e^{ij\lambda} \left(e^{ih\lambda} - \Phi_h(\lambda) \right) f(\lambda) d\lambda = 0. \tag{32}
 \end{aligned}$$

Označme

$$\Psi_h(\lambda) := \left(e^{ih\lambda} - \Phi_h(\lambda) \right) f(\lambda).$$

Potom (32) lze zapsat ve tvaru

$$\int_{-\pi}^{\pi} e^{ij\lambda} \Psi_h(\lambda) d\lambda = 0, \quad j = 1, 2, \dots. \quad (33)$$

Z podmínky (33) vyplývá, že Fourierův rozvoj funkce Ψ_h bude obsahovat pouze členy s nezápornými mocninami $e^{i\lambda}$,

$$\Psi_h(\lambda) = \sum_{k=0}^{\infty} b_k e^{ik\lambda}, \quad \sum_{k=0}^{\infty} |b_k| < \infty.$$

Bude-li

$$\Phi_h(\lambda) = \sum_{k=1}^{\infty} a_k e^{-ik\lambda}, \quad \sum_{k=1}^{\infty} |a_k| < \infty,$$

což je funkce, která je konvergentní v $L_2(F)$, potom

Predikce
v časové
doméně

Projekce
v Hilbertově
prostoru

Predikce
založená na
konečné
minulosti

Predikce
založená na
nekonečné
minulosti

Predikce ve
spektrální
doméně

$$\begin{aligned}\widehat{X}_{n+h}(n-1) &= \int_{-\pi}^{\pi} e^{in\lambda} \left[\sum_{k=1}^{\infty} a_k e^{-ik\lambda} \right] dZ(\lambda) \\ &= \text{l. i. m. }_{N \rightarrow \infty} \int_{-\pi}^{\pi} e^{in\lambda} \left[\sum_{k=1}^N a_k e^{-ik\lambda} \right] dZ(\lambda) \\ &= \text{l. i. m. }_{N \rightarrow \infty} \sum_{k=1}^N a_k \left[\int_{-\pi}^{\pi} e^{i(n-k)\lambda} dZ(\lambda) \right] \\ &= \text{l. i. m. }_{N \rightarrow \infty} \sum_{k=1}^N a_k X_{n-k} = \sum_{k=1}^{\infty} a_k X_{n-k}.\end{aligned}$$

Věta 54:

Nechť $\{X_t, t \in \mathbb{Z}\}$ je reálná centrovaná stacionární posloupnost s autokovarianční funkcí R a spektrální hustotou $f(\lambda) = f^*(e^{i\lambda})$, kde f^* je racionální funkce komplexní proměnné.

Nechť funkce Φ_h^* je funkce komplexní proměnné, holomorfní vně a na hranici jednotkového kruhu a taková, že $\Phi_h^*(\infty) = 0$.

Nechť funkce

$$\Psi_h^*(z) = \left(z^h - \Phi_h^*(z) \right) f^*(z), \quad z \in \mathbb{C},$$

je holomorfní uvnitř a na hranici jednotkového kruhu. Potom nejlepší lineární predikce prvku X_{n+h} na základě

X_{n-1}, X_{n-2}, \dots je

$$\widehat{X}_{n+h}(n-1) = \int_{-\pi}^{\pi} e^{in\lambda} \Phi_h(\lambda) dZ(\lambda),$$

kde $\Phi_h(\lambda) = \Phi_h^*(e^{i\lambda})$ a $\{Z_\lambda, \lambda \in [-\pi, \pi]\}$ je proces s ortogonálními přírůstky ze spektrálního rozkladu $\{X_t, t \in \mathbb{Z}\}$.

Chyba predikce je

$$\delta_h^2 = E|X_{n+h} - \hat{X}_{n+h}(n-1)|^2 \\ = R(0) - \int_{-\pi}^{\pi} |\Phi_h(\lambda)|^2 f(\lambda) d(\lambda) \quad (34)$$

$$= R(0) - \int_{-\pi}^{\pi} e^{-ih\lambda} \Phi_h(\lambda) f(\lambda) d\lambda. \quad (35)$$

Důkaz: Anděl (1976), kap. X, věta 8. □

Funkce Φ_h se nazývá **spektrální charakteristika predikce** prvku X_{n+h} na základě X_{n-1}, X_{n-2}, \dots

Příklad (AR(1)):

Zuzana
PráškováPredikce
v časové
doméněProjekce
v Hilbertově
prostoruPredikce
založená na
konečné
minulostiPredikce
založená na
nekonečné
minulostiPredikce ve
spektrální
doméně

$$X_t = \varphi X_{t-1} + Y_t, |\varphi| < 1, \varphi \neq 0, Y_t \sim WN(0, \sigma^2).$$

Hledáme předpověď $\hat{X}_{n+h}(n-1)$ ve spektrální doméně, když známe $X_{n-1}, X_{n-2}, \dots, h \geq 0$.

Spektrální hustota posloupnosti $\{X_t, t \in \mathbb{Z}\}$ je

$$f(\lambda) = \frac{\sigma^2}{2\pi} \frac{1}{|1 - \varphi e^{-i\lambda}|^2} = \frac{\sigma^2}{2\pi} \frac{1}{(1 - \varphi e^{-i\lambda})(1 - \varphi e^{i\lambda})} = f^*(e^{i\lambda}),$$

kde

$$f^*(z) = \frac{\sigma^2}{2\pi} \frac{1}{(1 - \varphi z^{-1})(1 - \varphi z)} = \frac{\sigma^2}{2\pi} \frac{z}{(1 - \varphi z)(z - \varphi)}$$

je racionální funkce komplexní proměnné z .

$$\Psi_h^*(z) = \left(z^h - \Phi_h^*(z)\right) f^*(z) = \frac{\sigma^2}{2\pi} \frac{z(z^h - \Phi_h^*(z))}{(1 - \varphi z)(z - \varphi)}, z \in \mathbb{C},$$

Podmínkám věty vyhovují funkce

$$\Phi_h^*(z) = \frac{\varphi^{h+1}}{z} = \varphi^{h+1} z^{-1}, \quad z \in \mathbb{C},$$

$$\Psi_h^*(z) = \frac{\sigma^2}{2\pi} \frac{z^{h+1} - \varphi^{h+1}}{(z - \varphi)(1 - \varphi z)}, \quad z \in \mathbb{C},$$

spektrální charakteristika predikce je $\Phi_h(\lambda) = \varphi^{h+1} e^{-i\lambda}$ a nejlepší lineární předpověď

$$\begin{aligned}\widehat{X}_{n+h}(n-1) &= \int_{-\pi}^{\pi} e^{in\lambda} \Phi_h(\lambda) dZ(\lambda) \\ &= \int_{-\pi}^{\pi} e^{in\lambda} \varphi^{h+1} e^{-i\lambda} dZ(\lambda) \\ &= \int_{-\pi}^{\pi} e^{i(n-1)\lambda} dZ(\lambda) \varphi^{h+1} = \varphi^{h+1} X_{n-1}.\end{aligned}$$

Dostali jsme stejný výsledek jako v časové doméně.

Chyba predikce: Podle vzorce (34) máme

$$\begin{aligned}\delta_h^2 &= \text{E} |X_{t+h} - \hat{X}_{t+h}(t-1)|^2 = \|X_{t+h}\|^2 - \|\hat{X}_{t+h}(t-1)\|^2 \\ &= R(0) - \text{E} |\hat{X}_{t+h}(t-1)|^2 = R(0) - \text{E} \left| \int_{-\pi}^{\pi} e^{it\lambda} \Phi_h(\lambda) dZ(\lambda) \right|^2 \\ &= R(0) - \int_{-\pi}^{\pi} \left| e^{it\lambda} \Phi_h(\lambda) \right|^2 f(\lambda) d\lambda = \\ &= R(0) - |\varphi|^{2(h+1)} \int_{-\pi}^{\pi} f(\lambda) d\lambda = R(0) \left(1 - \varphi^{2(h+1)} \right),\end{aligned}$$

což opět souhlasí s výsledkem v časové doméně.