

Pravděpodobnostní metody a matematická statistika

Prof. RNDr. Gejza Dohnal, CSc.

VIII. Náhodná posloupnost



<https://sms.nipax.cz/pas>

Náhodná posloupnost

Uvažujme posloupnost náhodných veličin X_1, \dots, X_n, \dots

$$X : \Omega \times N \longrightarrow R$$

System konečněrozměrných distribučních funkcí:

$$F(x_1, \dots, x_n; i_1, \dots, i_n) = P(X_{i_1} \leq x_1, \dots, X_{i_n} \leq x_n)$$

symetrie: $F(x_{i_1}, \dots, x_{i_n}; i_1, \dots, i_n) = F(x_{j_1}, \dots, x_{j_n}; j_1, \dots, j_n)$
pro libovolnou permutaci (j_1, \dots, j_n) čísel (i_1, \dots, i_n)
(nezáleží na pořadí)

konzistence:

$$\lim_{x_n \rightarrow \infty} F(x_1, \dots, x_n; i_1, \dots, i_n) = F(x_1, \dots, x_{n-1}; i_1, \dots, i_{n-1})$$

Náhodná posloupnost

Konvergence posloupnosti náhodných veličin

1) Konvergence skoro jistě:

$$P\left(\lim_{n \rightarrow \infty} X_n = X\right) = 1$$

silná konvergence, konvergence skoro všude

$$X_n \xrightarrow[n \rightarrow \infty]{s.j.} X$$

2) Konvergence v pravděpodobnosti:

$$\forall \epsilon > 0 : \lim_{n \rightarrow \infty} P[||X_n - x|| > \epsilon] = 0$$

slabá konvergence, konvergence podle míry

$$X_n \xrightarrow[n \rightarrow \infty]{P} X$$

3) Konvergence v distribuci:

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F(x)$$

$$X_n \xrightarrow[n \rightarrow \infty]{\mathcal{D}} X$$

4) Konvergence podle kvadratického středu:

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

konvergence v L_p normě pro $p=2$

$$X_n \xrightarrow[n \rightarrow \infty]{E^2} X$$

Náhodná posloupnost

Konvergence posloupnosti náhodných veličin

Platí

$$X_n \xrightarrow[n \rightarrow \infty]{s.j.} X \implies X_n \xrightarrow[n \rightarrow \infty]{P} X$$
$$X_n \xrightarrow[n \rightarrow \infty]{P} X \implies X_n \xrightarrow[n \rightarrow \infty]{\mathcal{D}} X$$

Zákony velkých čísel

Slabý zákon velkých čísel:

Řekneme, že posloupnost náhodných veličin $\{X_n\}_{n=1}^{\infty}$ splňuje slabý zákon velkých čísel, jestliže platí

$$Y_n = \frac{1}{n} \sum_{i=1}^n (X_i - EX_i) \xrightarrow[n \rightarrow \infty]{P} 0.$$

Čebyševova věta:

Nechť $\{X_n\}_{n=1}^{\infty}$ je posloupnost po dvou nezávislých náhodných veličin, které mají konečné druhé momenty a platí

$$\lim_{n \rightarrow \infty} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = 0.$$

Potom tato posloupnost splňuje slabý zákon velkých čísel.

(Důkaz pomocí Čebyševovy nerovnosti: $\forall \varepsilon > 0 : P(|Y_n - EY_n| > \varepsilon) \leq \frac{\text{Var}Y_n}{\varepsilon^2}$.)

Zákony velkých čísel

Označme $Y_n = \frac{1}{n} \sum_{i=1}^n (X_i - EX_i)$

$$EY_n = E \left[\frac{1}{n} \sum_{i=1}^n (X_i - EX_i) \right] = \frac{1}{n} \sum_{i=1}^n \underbrace{E(X_i - EX_i)}_{=0} = 0$$

$$\begin{aligned} \text{Var}Y_n &= \text{Var} \left[\frac{1}{n} \sum_{i=1}^n (X_i - EX_i) \right] = \frac{1}{n^2} \text{Var} \left[\sum_{i=1}^n (X_i - EX_i) \right] \\ &\stackrel{\text{nez.}}{=} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i - EX_i) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}X_i \end{aligned}$$

$$P \left(\left| \frac{1}{n} \sum_{i=1}^n (X_i - EX_i) - 0 \right| > \varepsilon \right) \leq \frac{\text{Var}Y_n}{\varepsilon^2} = \frac{1}{\varepsilon^2} \frac{1}{n^2} \sum_{i=1}^n \text{Var}X_i \xrightarrow[n \rightarrow \infty]{\text{podle předp.}} 0,$$

$$\forall \varepsilon > 0 : P(|Y_n - EY_n| > \varepsilon) \leq \frac{\text{Var}Y_n}{\varepsilon^2}.$$

Zákony velkých čísel

Bernoulliiova věta:

Nechť náhodná veličina Y_n je rovna počtu úspěchů v posloupnosti nezávislých alternativních pokusů délky n , ve které je pravděpodobnost úspěchu rovna číslu $\theta \in (0, 1)$. Potom posloupnost $Z_n = \frac{1}{n}Y_n$ relativních četností úspěchů konverguje podle pravděpodobnosti k θ , tj.

$$Z_n = \frac{1}{n}Y_n \xrightarrow[n \rightarrow \infty]{P} \theta.$$

Chinčinoва věta:

Nechť $\{X_n\}_{n=1}^{\infty}$ je posloupnost nezávislých náhodných veličin se stejným rozdělením s konečnou střední hodnotou $EX_i = \mu$. Potom $\{X_n\}_{n=1}^{\infty}$ splňuje slabý zákon velkých čísel, tj. pro posloupnost průměrů platí

$$\frac{1}{n} \sum_{i=1}^n X_i = Y_n \xrightarrow[n \rightarrow \infty]{P} \mu.$$

Zákony velkých čísel

Silný zákon velkých čísel:

Řekneme, že posloupnost náhodných veličin $\{X_n\}_{n=1}^{\infty}$ splňuje slabý zákon velkých čísel, jestliže platí

$$P \left(\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n (X_i - EX_i) = 0 \right) = 1.$$

Centrální limitní věta (Lindeberg-Lévy):

Nechť $\{X_n\}_{n=1}^{\infty}$ je posloupnost nezávislých náhodných veličin se stejným rozdělením se střední hodnotou μ a nenulovým rozptylem σ^2 . Potom náhodné veličiny

$$U_{\bar{X}_n} = \frac{\sum_{i=1}^n (X_i - \mu_i)}{\sigma \sqrt{n}}$$

konvergují v distribuci k náhodné veličině se standardním normálním rozdělením $N(0,1)$.

Zákony velkých čísel

Moivre-Laplaceova věta:

Nechť náhodná veličina Y_n je rovna počtu úspěchů v posloupnosti nezávislých alternativních pokusů délky n , ve které je pravděpodobnost úspěchu rovna číslu $\theta \in (0, 1)$. Potom

$$\frac{Y_n - n\theta}{\sqrt{n\theta(1 - \theta)}} \xrightarrow[n \rightarrow \infty]{\mathcal{D}} Z.$$

kde Z je náhodná veličina se standardním normálním rozdělením $N(0,1)$.

Příklad:

Spočtete přibližnou pravděpodobnost toho, že počet šestek, které padnou ve 12.000 hodech homogenní hrací kostkou, bude mezi 1.900 až 2.100.

Zákony velkých čísel

Řešení:

Označme Y_n počet šestek, které padnou v $n=12.000$ hodech; je

$Y_n \sim Bi\left(n, \frac{1}{6}\right)$ a hledáme $P(Y_n \in B) = P(1900 < Y_n \leq 2100)$

Dále je $EY_n = n\theta = 12000 \frac{1}{6} = 2000$

$$VarY_n = n\theta(1 - \theta) = 12000 \frac{1}{6} \frac{5}{6} = 2000 \frac{5}{6} = \frac{10000}{6}.$$

$$P(1900 < Y_n \leq 2100) = P(1900 - EY_n < Y_n - EY_n \leq 2100 - EY_n)$$

$$= P\left(\frac{1900 - EY_n}{\sqrt{VarY_n}} < \frac{Y_n - EY_n}{\sqrt{VarY_n}} \leq \frac{2100 - EY_n}{\sqrt{VarY_n}}\right)$$

$$= P\left(\frac{1900 - 2000}{\sqrt{\frac{10000}{6}}} < U_{\bar{X}_n} \leq \frac{2100 - 2000}{\sqrt{\frac{10000}{6}}}\right)$$

$$= P(-2.4495 < U_{\bar{X}_n} \leq 2.4495)$$

$$\approx \Phi(2.4495) - \Phi(-2.4495)$$

$$= 2\Phi(2.4495) - 1 = \boxed{0.9857}.$$

Náhodná posloupnost

Charakteristiky posloupnosti náhodných veličin

funkce střední hodnoty: $\mu_i = E(X_i), \quad i = 1, \dots$

autokovarianční funkce: $c(i, j) = \text{Cov}(X_i, X_j) = E(X_i X_j) - E(X_i)E(X_j)$

autokorelační funkce: $r(i, j) = \rho(X_i, X_j) = \frac{\text{Cov}(X_i, X_j)}{\sqrt{\text{Var} X_i \cdot \text{Var} X_j}}$

Pokud je 1) $\mu_i = \mu, \quad i = 1, 2, \dots$ konstantní střední hodnota

2) $c(i, j) = c(j - i), \quad i = 1, 2, \dots, \quad j = 1, 2, \dots$

kovarianční funkce závisí jen na rozdílu indexů

potom řekneme, že posloupnost $\{X_n\}_{n=1}^{\infty}$ je **kovariančně (slabě) stacionární**.

Posloupnost $\{X_n\}_{n=1}^{\infty}$ je **silně stacionární**, pokud pro libovolnou n -tici i_1, \dots, i_n a libovolné $\delta \in N$ platí

$$F(x_{i_1}, \dots, x_{i_n}; i_1, \dots, i_n) = F(x_{i_1}, \dots, x_{i_n}; i_1 + \delta, \dots, i_n + \delta)$$

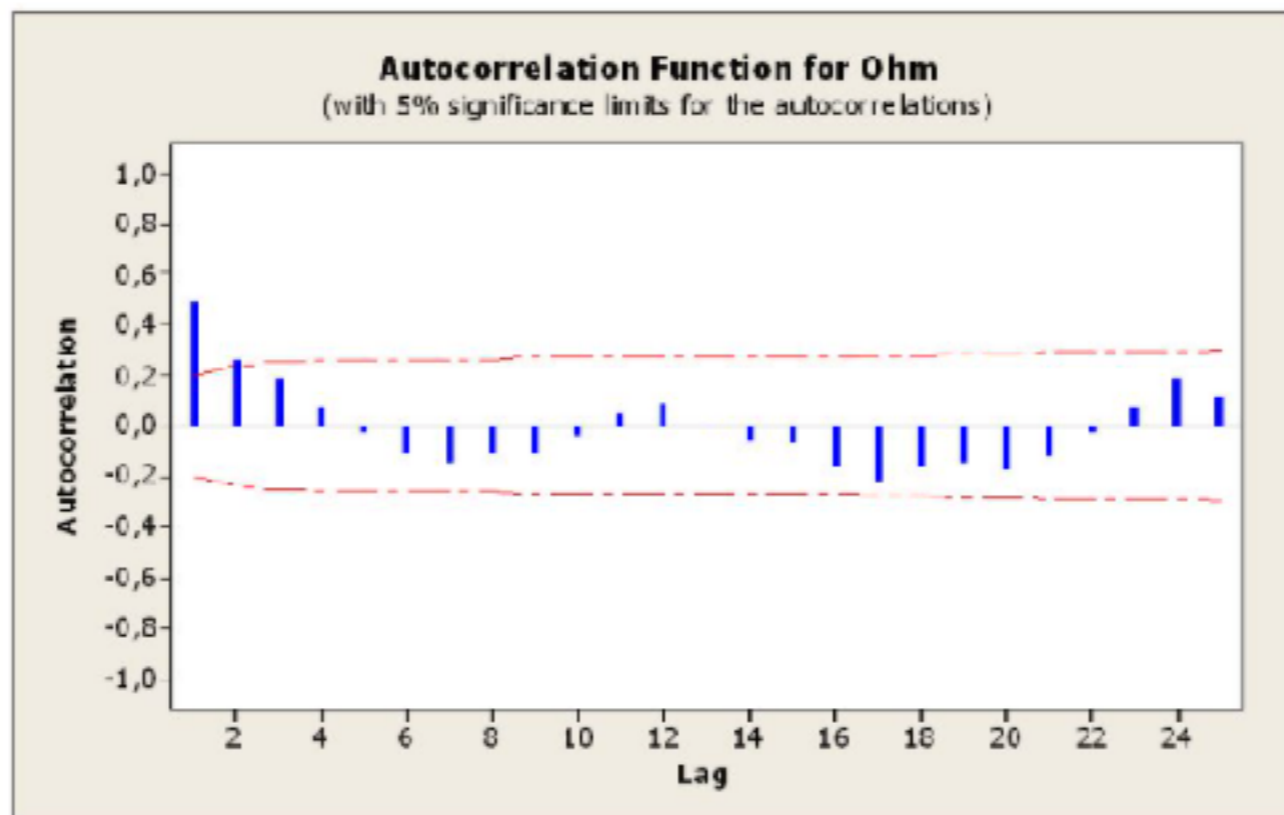
Stacionární náhodné posloupnosti

autokovarianční funkce: $c(k) = \text{Cov}(X_1, X_{k+1}) = \text{Cov}(X_i, X_{i+k+1})$
 $= E(X_1 - \mu)(X_{k+1} - \mu) = E(X_1, X_{k+1}) - \mu^2$

zpravidla pracujeme s tzv. “centrovaným” procesem: $Y_i = X_i - \mu$

a pro tento proces je $c(k) = E(Y_i Y_j)$

autokorelační funkce: $r(k) = \frac{c(k)}{c(0)}$ (vždy je $r(0) = 1$)




Náhodné posloupnosti

Posloupnost nekorelovaných náhodných veličin $\{\xi_i\}_{i=1}^{\infty}$

autokorelační funkce: $r(0) = 1, \quad r(k) = 0, \quad k = 1, \dots$

Posloupnost nezávislých náhodných veličin se stejným rozdělením s nulovou střední hodnotou a konstantním rozptylem
= bílý šum

Posloupnost nezávislých náhodných veličin s normálním rozdělením $N(0, \sigma^2)$ = Gaussovský bílý šum



Náhodné posloupnosti

Autoregresní posloupnost řádu p AR(p)

$$Y_k = \phi_1 Y_{k-1} + \dots + \phi_p Y_{k-p} + \epsilon_k$$

kde ϕ_i , $i = 1, \dots, p$ jsou konstanty a ϵ_k je bílý šum.

AR(1): $Y_k = \phi Y_{k-1} + \epsilon_k$

$$\text{Var}(Y_k) = \phi^2 \text{Var}(Y_{k-1}) + \sigma_\epsilon^2$$

je-li stacionární, potom musí být $\text{Var}(Y_k) = \text{Var}(Y_{k-1}) = \sigma_Y^2$

$$\sigma_Y^2 = \phi^2 \sigma_Y^2 + \sigma_\epsilon^2 \Rightarrow \sigma_Y^2 = \frac{\sigma_\epsilon^2}{1 - \phi^2} \Rightarrow 1 > \phi^2 \Rightarrow |\phi| < 1$$

autokovarianční funkce: $E(Y_k, Y_{k-u}) = \phi E(Y_{k-1}, Y_{k-u}) + E(\epsilon_k Y_{k-u})$

$$c(u) = \phi c(u-1), \quad u = 1, 2, \dots$$

$$c(u) = \phi^u c(0), \quad u = 1, 2, \dots$$

$$c(u) = \frac{\phi^u \sigma_\epsilon^2}{1 - \phi^2}$$

Náhodné posloupnosti

AR(1): $Y_k = \phi Y_{k-1} + \epsilon_k$

$$E(Y_k) = 0, \quad \text{Var}(Y_k) = \phi^2 \text{Var}(Y_{k-1}) + \sigma_\epsilon^2$$

je-li stacionární, potom musí být $\text{Var}(Y_k) = \text{Var}(Y_{k-1}) = \sigma_Y^2$

$$\sigma_Y^2 = \phi^2 \sigma_Y^2 + \sigma_\epsilon^2 \Rightarrow \sigma_Y^2 = \frac{\sigma_\epsilon^2}{1 - \phi^2} \Rightarrow 1 > \phi^2 \Rightarrow |\phi| < 1$$

autokovarianční funkce: $E(Y_k, Y_{k-u}) = \phi E(Y_{k-1}, Y_{k-u}) + E(\epsilon_k Y_{k-u})$

$$c(u) = \phi c(u-1), \quad u = 1, 2, \dots$$

$$c(u) = \phi^u c(0), \quad u = 1, 2, \dots$$

$$c(u) = \frac{\phi^u \sigma_\epsilon^2}{1 - \phi^2}$$

autokorelační funkce:

$$r(u) = \phi^u, \quad u = 1, 2, \dots$$

Náhodné posloupnosti


AR(1): $Y_k = \phi Y_{k-1} + \epsilon_k$

$E(Y_k) = 0, \quad Var(Y_k)$

je-li stacionární, potom

$$\sigma_Y^2 = \phi^2 \sigma_Y^2 + \sigma_\epsilon^2 \Rightarrow$$

autokovarianční funkce



$= \sigma_Y^2$

$- E(\epsilon_k Y_{k-u})$

, 2, ...

...

autokorelační funkce:

$$r(u) = \phi^u, \quad u = 1, 2, \dots$$


Náhodné posloupnosti

AR(2): $Y_k = \phi_1 Y_{k-1} + \phi_2 Y_{k-2} + \epsilon_k$


autokovarianční funkce: $c(u) = \alpha_1 \gamma_1^u + \alpha_2 \gamma_2^u$

kde γ_1, γ_2 jsou kořeny polynomu $1 - \phi_1 z - \phi_2 z^2 = 0$


$\phi_1 = 0.5, \phi_2 = 0.3$




$\phi_1 = 1, \phi_2 = -0.5$



$\phi_1 = -0.5, \phi_2 = 0.3$



$\phi_1 = -0.5, \phi_2 = -0.3$





Náhodné posloupnosti

AR(2): $Y_k = \phi_1 Y_{k-1} + \phi_2 Y_{k-2} + \epsilon_k$

autokovarianční funkce: $c(u) = \alpha_1 \gamma_1^u + \alpha_2 \gamma_2^u$

kde γ_1, γ_2 jsou kořeny polynomu $1 - \phi_1 z - \phi_2 z^2 = 0$



$$Y_k = 1.5Y_{k-1} - 0.75Y_{k-2} + \epsilon_k$$

Náhodné posloupnosti

Posloupnost klouzavých součtů řádu q MA(q)

$$Y_k = \epsilon_k + \theta_1 \epsilon_{k-1} + \dots + \theta_q \epsilon_{k-q}$$

kde θ_i , $i = 1, \dots, q$ jsou konstanty a ϵ_k je bílý šum.



autokovarianční funkce:

$$c(u) = \begin{cases} (1 + \theta_1^2 + \dots + \theta_q^2)\sigma^2 & u = 0, \\ (\theta_u + \theta_1\theta_{u+1} + \dots + \theta_{q-u}\theta_q)\sigma^2 & u = 1, \dots, q \\ 0 & \text{jinak} \end{cases}$$

MA(1): $Y_k = \epsilon_k + \theta\epsilon_{k-1}$

$$c(u) = \begin{cases} (1 + \theta^2)\sigma^2 & u = 0, \\ \theta\sigma^2 & u = 1, \\ 0 & \text{jinak} \end{cases} \quad r(u) = \begin{cases} \frac{\theta}{1+\theta^2} & u = 1, \\ 0 & \text{jinak} \end{cases}$$

Náhodné posloupnosti



MA(1): $Y_k = \epsilon_k + \theta\epsilon_{k-1}$

$$c(u) = \begin{cases} (1 + \theta^2)\sigma^2 & u = 0, \\ \theta\sigma^2 & u = 1, \\ 0 & \text{jinak} \end{cases}$$

$$r(u) = \begin{cases} \frac{\theta}{1 + \theta^2} & u = 1, \\ 0 & \text{jinak} \end{cases}$$

Náhodné posloupnosti

Posloupnost ARMA(p,q)

$$Y_k = \phi_1 Y_{k-1} + \cdots + \phi_p Y_{k-p} + \epsilon_k + \theta_1 \epsilon_{k-1} + \cdots + \theta_q \epsilon_{k-q}$$

$$\text{ARMA}(1,1): Y_k = \phi Y_{k-1} + \epsilon_k + \theta \epsilon_{k-1}$$

autokovarianční funkce:

$$E(\epsilon_k Y_k) = E(\epsilon_k (\phi Y_{k-1} + \epsilon_k + \theta \epsilon_{k-1})) = \sigma_\epsilon^2$$

$$E(\epsilon_{k-1} Y_k) = E(\epsilon_{k-1} (\phi Y_{k-1} + \epsilon_k + \theta \epsilon_{k-1})) = (\phi + \theta) \sigma_\epsilon^2$$

·
·
·



$$c(u) = \frac{(1 + \theta\phi)(\phi + \theta)}{1 + 2\theta\phi + \theta^2} \phi^{u-1} \sigma_\epsilon^2, \quad v \geq 1$$

$$r(u) = \frac{(1 + \theta\phi)(\phi + \theta)}{1 + 2\theta\phi + \theta^2} \phi^{u-1}, \quad v \geq 1$$

Náhodné posloupnosti

Posloupnost ARMA(p,q)

$$Y_k = -0.5Y_{k-1} + \epsilon_k + 0.3\epsilon_{k-1}$$



$$c(u) = \frac{(1 + \theta\phi)(\phi + \theta)}{1 + 2\theta\phi + \theta^2} \phi^{u-1} \sigma_\epsilon^2, \quad v \geq 1$$

$$r(u) = \frac{(1 + \theta\phi)(\phi + \theta)}{1 + 2\theta\phi + \theta^2} \phi^{u-1}, \quad v \geq 1$$

Náhodné posloupnosti

Parciální autokorelační funkce (PACF)

$$a(u) = \rho(Y_k, Y_{k-u} \mid Y_{k-1}, \dots, Y_{k-u+1})$$




AR(1): $r(u) = \phi^u, u \geq 1, \quad a(1) = \phi, \quad a(u) = 0, u \geq 2.$

MA(1): $r(1) = \frac{\theta}{1 + \theta^2}, r(u) = 0, u \geq 2, \quad a(u) = \frac{-\theta^u(1 - \theta^2)}{1 - \theta^{2(r+1)}}, u \geq 0.$

Náhodné posloupnosti

Posloupnost ARMA(p,q)

$$Y_k = -0.5Y_{k-1} + \epsilon_k + 0.3\epsilon_{k-1}$$



Náhodné posloupnosti

Vyhlazování časové posloupnosti: $Y_k = f(k) + \epsilon_k$

Regresní křivka (trend): $Y_k = \beta_0 + \epsilon_k$

$$Y_k = \beta_0 + \beta_1 k + \epsilon_k$$

$$Y_k = \beta_0 + \beta_1 k + \beta_2 k^2 + \epsilon_k$$

$$Y_k = \beta_0 \cdot \beta^k + \epsilon_k$$

Příklad - lineární trend: $f(k; \beta_0, \beta_1) = \beta_0 + \beta_1 k$

parametry β_0, β_1 odhadneme metodou nejmenších čtverců
- minimalizujeme funkci kvadratických odchylek členů posloupnosti a hodnot funkce trendu v nějakém okně $k=1, \dots, n$

ve tvaru

$$g(k; \beta_0, \beta_1) = \sum_{k=1}^n (Y_k - f(k; \beta_0, \beta_1))^2$$

$$\frac{\partial g(k; \beta_0, \beta_1)}{\partial \beta_0} = 0$$

$$\frac{\partial g(k; \beta_0, \beta_1)}{\partial \beta_1} = 0$$

\Rightarrow

$$\beta_0 n + \beta_1 \sum_{k=1}^n t_k = \sum_{k=1}^n y_k$$

$$\beta_0 \sum_{k=1}^n t_k + \beta_1 \sum_{k=1}^n t_k^2 = \sum_{k=1}^n t_k y_k$$

Náhodné posloupnosti

Vyhlazování časové posloupnosti: $Y_k = f(k) + \epsilon_k$

Příklad - lineární trend: $f(k; \beta_0, \beta_1) = \beta_0 + \beta_1 k$

parametry β_0, β_1 odhadneme metodou nejmenších čtverců
- minimalizujeme funkci kvadratických odchylek členů posloupnosti a hodnot funkce trendu v nějakém okně $k=1, \dots, n$

ve tvaru $g(k; \beta_0, \beta_1) = \sum_{k=1}^n (Y_k - f(k; \beta_0, \beta_1))^2$

$$\begin{aligned} \frac{\partial g(k; \beta_0, \beta_1)}{\partial \beta_0} = 0 & \quad b_0 n + b_1 \sum_{k=1}^n t_k = \sum_{k=1}^n y_k \\ \frac{\partial g(k; \beta_0, \beta_1)}{\partial \beta_1} = 0 & \quad b_0 \sum_{k=1}^n t_k + b_1 \sum_{k=1}^n t_k^2 = \sum_{k=1}^n t_k y_k \end{aligned} \Rightarrow$$

$$b_1 = \frac{\sum_{k=1}^n t_k y_k - \bar{t} \sum_{k=1}^n y_k}{\sum_{k=1}^n t_k^2 - n \bar{t}^2}, \quad b_0 = \bar{y} - b_1 \bar{t}$$

Náhodné posloupnosti

Vyhlazování časové posloupnosti: $Y_k = f(k) + \epsilon_k$

Příklad - lineární trend: $f(k; \beta_0, \beta_1) = \beta_0 + \beta_1 k$

$$b_1 = \frac{\sum_{k=1}^n t_k y_k - \bar{t} \sum_{k=1}^n y_k}{\sum_{k=1}^n t_k^2 - n\bar{t}^2}, \quad b_0 = \bar{y} - b_1 \bar{t}$$

má-li ϵ_k normální rozdělení $N(0, \sigma^2)$, potom můžeme vyhodnotit i spolehlivost takového odhadu:

$$s^2 = \frac{1}{n-2} \left(\sum_{k=1}^n y_k^2 - b_0 \sum_{k=1}^n y_k - b_1 \sum_{k=1}^n t_k y_k \right) \quad \text{odhad rozptylu } \sigma^2$$

$$S_0^2 = \frac{s^2 \sum_{k=1}^n t_k^2}{n \sum_{k=1}^n t_k^2 - n\bar{t}^2} \quad S_1^2 = \frac{s^2}{n \sum_{k=1}^n t_k^2 - n\bar{t}^2} \quad \text{odhad rozptylu } b_1$$

odhad rozptylu b_0

$$b_i - S_i t_{1-\alpha/2}(n-2) \leq \beta_i \leq b_i + S_i t_{1-\alpha/2}(n-2), \quad i = 0, 1$$

100(1- α)%-interval spolehlivosti pro koeficienty β_0 a β_1

Náhodné posloupnosti

Vyhlazování časové posloupnosti: $Y_k = f(k) + \epsilon_k$

Příklad - lineární trend: $f(k; \beta_0, \beta_1) = \beta_0 + \beta_1 k$

$$b_1 = \frac{\sum_{k=1}^n t_k y_k - \bar{t} \sum_{k=1}^n y_k}{\sum_{k=1}^n t_k^2 - n \bar{t}^2}, \quad b_0 = \bar{y} - b_1 \bar{t}$$

má-li ϵ_k normální rozdělení $N(0, \sigma^2)$, potom můžeme provést predikci $\tilde{y}_T = b_0 + b_1 T$ pro nějakou budoucí hodnotu T :

100(1- α)%-interval spolehlivosti pro predikci má potom tvar


$$\tilde{y}_T - t_{1-\alpha/2}(n-2) \cdot F_T \leq Y_T \leq \tilde{y}_T + t_{1-\alpha/2}(n-2) \cdot F_T$$

kde
$$F_T = s \cdot \sqrt{1 + \frac{1}{n} + \frac{(T - \bar{t})^2}{\sum_{k=1}^n t_k^2 - n \bar{t}^2}}$$

Náhodné posloupnosti

Vyhlazování časové posloupnosti: $Y_k = f(k) + \epsilon_k$

Klouzavé průměry: $y_k^* = \frac{1}{m+n+1} \sum_{i=-m}^n y_{k+i}$




klouzavé průměry délky 5 ($m=2, n=2$)

Náhodné posloupnosti

Vyhlazování časové posloupnosti: $Y_k = f(k) + \epsilon_k$

Klouzavé průměry: $y_k^* = \frac{1}{m + n + 1} \sum_{i=-m}^n y_{k+i}$



klouzavé průměry délky 15 ($m=7, n=7$)


Náhodné posloupnosti

Vyhlazování časové posloupnosti: $Y_k = f(k) + \epsilon_k$

Klouzavé průměry: $y_k^* = \frac{1}{m+n+1} \sum_{i=-m}^n y_{k+i}$


Klouzavé mediány: $y_k^* = med(y_{k-m}, \dots, y_k, \dots, y_{k+n})$

Exponenciální vyhlazování: $y_k^* = (1 - \lambda)y_{k-1}^* + \lambda y_k$




Náhodné posloupnosti

Dekompozice časové posloupnosti: $Y_k = T_k + S_k + C_k + \epsilon_k$




Náhodné posloupnosti

Dekompozice časové posloupnosti: $Y_k = T_k + S_k + C_k + \epsilon_k$



Náhodné posloupnosti

Dekompozice časové posloupnosti: $Y_k = T_k + S_k + C_k + \epsilon_k$



Náhodné posloupnosti

Dekompozice časové posloupnosti: $Y_k = T_k + S_k + C_k + \epsilon_k$

