

Analýza časových řad

Pavla Holubíková

- 1 Stacionární procesy
- 2 Autokovarianční funkce a její vlastnosti
- 3 Derivace a integrál náhodného procesu
- 4 Spektrální rozklad autokovariančních funkcí stacionárních procesů
- 5 Odhady středních hodnot a autokovariancí stacionárních náhodných procesů
- 6 Regresní modely globálního a lokálního trendu

Znaky:

- 1 Data jsou sbírána postupně v čase.
- 2 Záleží na pořadí.
- 3 Pozorování jsou vzájemně závislá.

Cíle:

- 1 Porozumět datům; podle jakého modelu vznikají nové hodnoty.
- 2 Předpovídat budoucí hodnoty na základě minulých.

Nechť (Ω, \mathcal{A}, P) je pravděpodobnostní prostor, $T \subseteq \mathbb{R}$ indexová množina a $X : \Omega \rightarrow \mathbb{R}$ reálná funkce definovaná $\forall \omega \in \Omega$ a $\forall t \in T$. Jestliže $\forall t \in T$ je $X(\omega, t)$ borelovsky měřitelná funkce vzhledem k \mathcal{A} , pak tuto funkci nazýváme náhodným procesem. Značíme $\{X(\omega, t) : \omega \in \Omega, t \in T\} = \{X_t, t \in T\}$.

Borelovsky měřitelná funkce (\mathcal{B} σ -algebra borelovských podmnožin)

$$\forall B \in \mathcal{B}, \forall t \in T : X^{-1}(B) = \{\omega \in \Omega : X(\omega, t) \in B\} \in \mathcal{A}.$$

$T \subseteq \mathbb{Z} \rightarrow$ proces s diskretním časem (časová řada)

$T \in [t_1, t_2], -\infty \leq t_1 < t_2 \leq \infty \rightarrow$ proces se spojitým časem

X_t nabývají diskretních hodnot \rightarrow proces s diskretními stavy

X_t nabývají hodnot z nějakého intervalu \rightarrow proces se spojitými stavy

Systém distribučních funkcí

Konečně dimenzionální distribuční funkce rozumíme funkci

$$F_{t_1, \dots, t_k}(x_1, \dots, x_k) = P(X_{t_1} \leq x_1, \dots, X_{t_k} \leq x_k), \forall k \in \mathbb{N}, t_1, \dots, t_k \in T.$$

Systém distribučních funkcí $\{F_{t_1, \dots, t_k} : k \in \mathbb{N}, t_1, \dots, t_k \in T\}$ s vlastnostmi

- $\lim_{x_{k+1} \rightarrow \infty} F_{t_1, \dots, t_k, t_{k+1}}(x_1, \dots, x_k, x_{k+1}) = F_{t_1, \dots, t_k}(x_1, \dots, x_k),$
- $F_{t_{i_1}, \dots, t_{i_k}}(x_{i_1}, \dots, x_{i_k}) = F_{t_1, \dots, t_k}(x_1, \dots, x_k)$ pro lib. permutaci (i_1, \dots, i_k) čísel $(1, \dots, k)$

nazveme *konzistentní*.

Daniell-Kolmogorova věta

Nechť $\{F_{t_1, \dots, t_k} : k \in \mathbb{N}, t_1, \dots, t_k \in T\}$ je konzistentní. Pak existuje $\{X_t, t \in T\}$ takový, že $\forall k \in \mathbb{N}, t_1, \dots, t_k \in T$ je sdružená distribuční funkce $(X_{t_1}, \dots, X_{t_k})$ právě F_{t_1, \dots, t_k} .

Procesy, jejichž konečně dimenzionální distribuce jsou všechny mnohorozměrné normální, se nazývají *gaussovské*.

- *Střední hodnota* NP je funkce

$$\mu_t = \mathbb{E}X_t, \quad t \in \mathbb{Z}.$$

- *Autokovarianční funkce* NP je funkce

$$\gamma(s, t) = \text{cov}(X_s, X_t) = \mathbb{E}[(X_s - \mu_s)(X_t - \mu_t)], \quad s, t \in \mathbb{Z}.$$

- *Autokorelační funkce (ACF)* NP je funkce

$$\rho(s, t) = \text{cor}(X_s, X_t) = \frac{\text{cov}(X_s, X_t)}{\sqrt{\text{var}X_s \text{var}X_t}}, \quad s, t \in \mathbb{Z}.$$

Píšeme:

$$\gamma(h) := \gamma(t, t + h) = \gamma(0, h)$$

a obdobně pro $\rho(h)$.


Řekneme, že $\{X_t, t \in T\}$ je *striktně stacionární*, pokud je sdružená distribuční funkce $(X_{t_1}, \dots, X_{t_k})$ stejná jako sdružená distribuce $(X_{t_1+h}, \dots, X_{t_k+h})$, $\forall k \in \mathbb{N}$, $t_1, \dots, t_k \in T$, $h \in \mathbb{Z}$, tj.
 $F_{t_1, \dots, t_k}(x_1, \dots, x_k) = F_{t_1+h, \dots, t_k+h}(x_1, \dots, x_k)$.

Řekneme, že $\{X_t, t \in T\}$ je (*slabě*) *stacionární*, pokud je μ_t konstantní v čase a $\gamma(s, t)$ závisí pouze na rozdílu $s - t$.

Striktní stacionarita \Rightarrow *slabá stacionarita*


Pro gaussovský NP: *striktní stacionarita* = *slabá stacionarita*

- *Bílý šum*: $\{\varepsilon_t\} \sim WN(0, \sigma^2)$,
kde $\{\varepsilon_t, t \in \mathbb{Z}\}$ je posloupnost náhodných veličin:
 $E\varepsilon_t = 0$, $\text{var}\varepsilon_t = \sigma^2$, $\text{cov}(\varepsilon_s, \varepsilon_t) = 0$ pro $s \neq t$
stacionární




- *Klouzavé průměry*: $\{X_t, t \in \mathbb{Z}\}$,
kde $X_t = (\varepsilon_t + \varepsilon_{t-1})/2$ pro $\{\varepsilon_t\} \sim WN(0, \sigma^2)$,
stacionární, neboť $\mu_t = 0$,
 $\gamma(t, t) = 0.5\sigma^2$, $\gamma(t, t+1) = 0.25\sigma^2$, $\gamma(t, t+h) = 0$ pro $|h| > 1$.

- *Náhodná procházka*: $\{X_t, t \in \mathbb{Z}\}$,
kde $X_t = \sum_{i=1}^t \varepsilon_i$ pro $\{\varepsilon_t\} \sim WN(0, \sigma^2)$,
nestacionární, neboť $\mu_t = 0$, pro $s < t$
 $\gamma(t, t) = t\sigma^2$, $\gamma(s, t) = \min(s, t)\sigma^2$.



- *Náhodná kosinová vlna* $\{X_t, t \in \mathbb{Z}\}$,
 kde $X_t = a \cos[2\pi(ft + \phi)]$ pro amplitudu a , frekvenci f (např. $f = 1/12$), náhodnou fází $\phi \in [0, 1]$ (tj. z nějakého rozdělení, $Rs([0, 1])$)
 stacionární, neboť $EX_t = 0$,
 $\gamma(s, t) = \frac{a^2}{2} \cos[2\pi f(s - t)]$.



$$\gamma(s, t) = \text{cov}(X_s, X_t), \quad s, t \in T$$

- pro NP s konečnými druhými momenty je pozitivně semidefinitní:

$$\forall k \in \mathbb{N}, t_1, \dots, t_k \in T, c_1, \dots, c_k \in \mathbb{R}$$

$$0 \leq \text{var} \left(\sum_{i=1}^k c_i X_{t_i} \right) = \sum_{i=1}^k \sum_{j=1}^k c_i c_j \gamma(t_i, t_j)$$

- Naopak: Pro pozitivně semidefinitní, konečnou fci g na $T \times T \exists$ NP: g je autokovarianční fce
- Platí:

$$\gamma(t, t) = \gamma(0) \geq 0 \quad \text{a} \quad |\gamma(s, t)| \leq \sqrt{\gamma(t, t) \cdot \gamma(s, s)}$$

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

Řekneme, že $\{X_t, t \in T\}$ je *spojitý podle středu v bodě* $t_0 \in T$, jestliže při $t \rightarrow t_0$ konvergují X_t k X_{t_0} podle kvadratického středu, tj.

$$E|X_t - X_{t_0}|^2 \rightarrow 0 \quad \text{pro} \quad t \rightarrow t_0.$$

Píšeme („limit in the mean“)

$$\text{l.i.m.}_{t \rightarrow t_0} X_t = X_{t_0}.$$

Je-li $\{X_t, t \in T\}$ spojité v každém bodě množiny T je *spojitý*.

Kritérium spojitosti

NP $\{X_t, t \in T\}$ je spojité \Leftrightarrow jeho $\gamma(s, t)$ je spojitá v bodech (s, t) , pro něž $s = t$.

Řekneme, že $\{X_t, t \in T\}$ má v bodě $t_0 \in T$ derivaci X'_{t_0} , jestliže pro $t_0 + h \in T$ platí

$$\text{l.i.m.}_{h \rightarrow 0} \frac{X_{t_0+h} - X_{t_0}}{h} = X'_{t_0}$$

Má-li NP derivaci ve všech bodech T říkáme, že NP má *derivaci*.

Nechť $T = (a, b)$ je konečný nedegenerovaný interval, $[T_1, T_2] \subset T$, kde $T_1 < T_2$. Pomocí dělení D_n intervalu $[T_1, T_2]$ takového, že $T_1 = t_0 < t_1 < \dots < t_n = T_2$ vytvoříme součet $I_n = \sum_{i=1}^n X_{t_i}(t_i - t_{i-1})$. Označme $\Delta_n = \max_{1 \leq i \leq n}(t_i - t_{i-1})$ normu dělení D_n .

Jestliže posloupnost I_n konverguje podle kvadratického středu k náh. veličině I pro $n \rightarrow \infty$ pro lib. dělení D_n takové, že $\Delta_n \rightarrow 0$, pak se I nazývá *Riemannův integrál* $\{X_t, t \in T\}$ na $[T_1, T_2]$. Píšeme $I = \int_{T_1}^{T_2} X_t dt$.

Kritérium existence integrálu

Nechť $\{X_t, t \in T\}$ je NP s $EX_t = 0$, $\gamma(s, t)$ a konečnými 2. momenty. Pak R.I. $\int_{T_1}^{T_2} X_t dt \exists \Leftrightarrow \exists$ R.I. $\int_{T_1}^{T_2} \int_{T_1}^{T_2} \gamma(s, t) ds dt$.

Spektrální rozklad $\gamma(t)$

Předpoklad: $\{X_t, t \in \mathbb{Z}\}$ stacionární, $EX_t = 0$, konečné 2. momenty
 $\Rightarrow \gamma(t)$ jako (nespočetný) součet harmonických fcí s různými frekvencemi a amplitudami

Herglotzova věta

Je-li $\{X_t, t \in \mathbb{Z}\}$ stacionární posloupnost, pak se dá její $\gamma(t)$ vyjádřit jako

$$\gamma(t) = \int_{-\pi}^{\pi} e^{it\lambda} dF(\lambda). \quad (1)$$

Bochnerova věta

Je-li $\{X_t, t \in \mathbb{R}\}$ stacionární NP a spojitý podle středu, pak se dá $\gamma(t)$ vyjádřit jako

$$\gamma(t) = \int_{-\infty}^{\infty} e^{it\lambda} dF(\lambda). \quad (2)$$

$F(\lambda)$ neklesající, zprava spojitá a jediná:

$$F(-\pi) = 0 \text{ a } F(\pi) = \gamma(0), \quad \text{příp.} \quad F(-\infty) = 0 \text{ a } F(\infty) = \gamma(0)$$

Vzorce (1) a (2) se nazývají *spektrální rozklad* $\gamma(t)$.

Fce $F(\lambda)$ se nazývá *spektrální distribuční funkce*.

Je-li $F(\lambda)$ absolutně spojitá, pak existuje *spektrální hustota* $f(\lambda)$: pro stacionární posloupnosti (NP) platí

$$F(\lambda) = \int_{-\pi}^{\lambda} f(x) dx, \quad \text{příp.} \quad F(\lambda) = \int_{-\infty}^{\lambda} f(x) dx$$

Spektrální hustota $f(\lambda)$ reálného spojitého stacionárního NP nebo reálné stacionární posloupnosti je sudá fce v tom smyslu, že pro ni platí $f(\lambda) = f(-\lambda)$ s.v. vzhledem k Lebesgueově míře.

Existence spektrální hustoty

K existenci $f(\lambda)$ stacionární posloupnosti stačí, aby platilo

$$\sum_{t=-\infty}^{\infty} |\gamma(t)| < \infty.$$

K existenci $f(\lambda)$ stacionárního NP stačí, aby platilo

$$\int_{-\infty}^{\infty} |\gamma(t)| dt < \infty.$$

Existuje-li $f(\lambda)$ stacionární posloupnosti a má-li konečnou variaci na $[-\pi, \pi]$, pak $f(\lambda) = \frac{1}{2\pi} \sum_{t=-\infty}^{\infty} e^{-it\lambda} \gamma(t)$ s.v. vzhledem k Lebesgueově míře (tj. ve všech bodech spojitosti).

Existuje-li $f(\lambda)$ spojitého stacionárního NP a je-li $\int_{-\infty}^{\infty} |\gamma(t)| dt < \infty$, pak $f(\lambda) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-it\lambda} \gamma(t) dt$.

Odhady středních hodnot stacionárních NP

Předpokládejme, že $\mathbb{E}X_t = \mu$, $\forall t \in T$. Jako odhad zvolíme výběrový průměr

$$\hat{\mu} = \bar{X} = \frac{1}{n} \sum_{t=1}^n X_t.$$

- nestranný odhad: $\mathbb{E}\hat{\mu} = \mathbb{E}\left(\frac{1}{n} \sum_{t=1}^n X_t\right) = \mu$
- míra kvality odhadu pomocí rozptylu

$$\begin{aligned} \text{var}\hat{\mu} &= \text{var}\left(\frac{1}{n} \sum_{t=1}^n X_t\right) = \frac{1}{n^2} \sum_{t=1}^n \sum_{i=1}^n \text{cov}(X_t, X_i) = \\ &= \frac{1}{n^2} \{n\gamma(0) + 2(n-1)\gamma(1) + \dots + 2\gamma(n-1)\} \\ &= \frac{\gamma(0)}{n} \left\{1 + 2 \sum_{i=1}^{n-1} \frac{n-i}{n} \rho(i)\right\} \end{aligned}$$

(WN: $\text{var}\hat{\mu} = \frac{\gamma(0)}{n} \Rightarrow 2 \sum_{i=1}^{n-1} \frac{n-i}{n} \rho(i)$ korekční člen, odráží vliv autokorelace)

Konzistentnost

Nechť $\{X_t, t \in T\}$ je stacionární s μ a $\gamma(h) \rightarrow 0$ pro $h \rightarrow \infty$. Pak $\text{var} \bar{X}_n \rightarrow 0$ pro $n \rightarrow \infty$.

Aproximované rozdělení

Nechť $\{X_t, t \in T\}$ je stacionární. Pak za určitých podmínek má \bar{X}_n přibližně (pro velká n) normální rozdělení:

$$\bar{X}_n \xrightarrow{d} N \left(\mu, \frac{1}{n} \sum_{h=-\infty}^{\infty} \gamma(h) \right)$$





Odhady autokovariance stacionárních NP

Odhad $\gamma(h) = \mathbb{E}(X_t - \mu)(X_{t+h} - \mu)$ (příp. $n - h$ namísto n):

$$\hat{\gamma}(h) = \frac{1}{n} \sum_{i=1}^{n-h} (X_i - \bar{X})(X_{i+h} - \bar{X}).$$

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

$$\hat{\rho}(h) = \frac{\hat{\gamma}(h)}{\hat{\gamma}(0)} = \frac{\sum_{i=1}^{n-h} (X_i - \bar{X})(X_{i+h} - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2}.$$



Ozn. $\hat{c}(h) = (\hat{\gamma}(0), \dots, \hat{\gamma}(h))'$ a $\hat{r}(h) = (\hat{\rho}(1), \dots, \hat{\rho}(h))'$

Je-li $\{X_t, t \in T\}$ stacionární s konečnými 4. momenty, pak má $\hat{c}(h)$ za určitých podmínek pro lib. pevné h přibližně (pro $n \rightarrow \infty$) normální rozdělení:

$$\sqrt{n} (\hat{c}(h) - c(h)) \xrightarrow{d} N_{h+1}(0, V).$$

Mnohdy lepší studovat závislost bez ohledu na měřítko \rightarrow ACF
($\rho()$ = fce $\gamma()$ \Rightarrow *delta metoda*)

Je-li $\{X_t, t \in T\}$ stacionární s konečnými 4. momenty, pak má $\hat{r}(h)$ za určitých podmínek pro lib. pevné h přibližně (pro $n \rightarrow \infty$) normální rozdělení:

$$\sqrt{n} (\hat{r}(h) - r(h)) \xrightarrow{d} N_h(0, W),$$

kde $W = \{w_{ij}\}_{i,j=1,\dots,h}$ a

$$w_{ij} = \sum_{k=1}^{\infty} \{\rho(k+i) + \rho(k-i) + 2\rho(i)\rho(k)\} \{\rho(k+j) + \rho(k-j) + 2\rho(j)\rho(k)\}.$$

Popisujeme pomocí


$$\begin{aligned}X_t &= \text{DeterministickaCast}_t + \text{StochastickaCast}_t \\ &= \{\text{Trend}_t + \text{Sezonnost}_t\} + \{\text{PredikovatelnaVariabilita}_t + \varepsilon_t\} \\ &= T_t + S_t + E_t\end{aligned}$$

tj. *aditivní model* (příp. $X_t = T_t \cdot S_t \cdot E_t$ *multiplikativní*, který lze převést na aditivní zlogaritmováním)

- Trend – odráží dlouhodobé působení vlivů
- Sezonnost – popisuje periodické změny (roční období...)
- Náhodné fluktuace – modeluje vlivy, které působí nepravidelně

- tj. rozklad $X_t = T_t + S_t + E_t$ (v případě aditivního modelu)
- založeno na regresní analýze
- T_t se mění v čase flexibilně, S_t konstantní
- Postup:
 - 1 Odhad T_t
 - 2 „Odtrendování“ $X_t - T_t$
 - 3 Odhad sezonnosti S_t z $X_t - T_t$
 - 4 Výpočet reziduální složky $E_t = X_t - T_t - S_t$
- Pro odhady složek se využívají metody:
 - parametrické – lineární modely, harmonické LRM
 - neparametrické – metoda klouzavých průměrů, jádrové vyhlazování
- Jiné metody – STL dekompozice, exponenciální vyhlazování, Holt-Winter (včetně predikce)

Decomposition of additive time series



Regresní modely můžeme dělit na modely:

- *globálního trendu* – využití všech $t \in T$
- *lokálního trendu* – volba určitého počtu $t \in T$, tj. intervalu

Uvažujme $X_t = \mu_t + U_t$, kde $\mu_t = \mathbb{E}X_t$ a rezidua $U_t : \mathbb{E}U_t = 0$.

Trend můžeme uvažovat jako polynom (LRM), v praxi buď:

- lineární $\mu_t = \beta_0 + \beta_1 t$, nebo
- kvadratický $\mu_t = \beta_0 + \beta_1 t + \beta_2 t^2$.

Vhodné je zahrnout i sezonní složku (s sezón, $k \in \mathbb{N}_0$)

$$\mu_t = \beta_0 + \beta_1 t + \sum_{j=2}^s \alpha_j 1_{[t=ks+j]}.$$

Metoda klouzavých průměrů

Uvažujme $X_t = T_t + E_t$.

Trend můžeme modelovat také neparametricky pomocí klouzavých průměrů:





- tzn. průměrujeme hodnoty vždy na určitém intervalu
- řádu $m = 2k + 1$

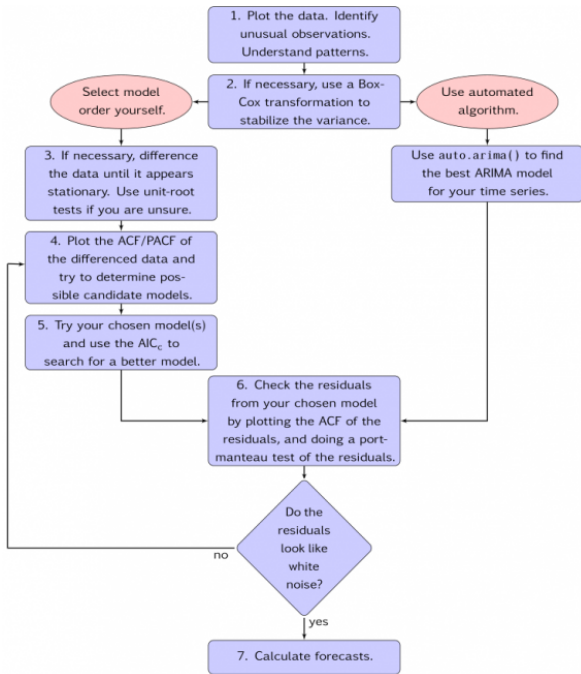
$$\hat{T}_t = \frac{1}{m} \sum_{j=-k}^k X_{t+j}$$

- řádu $m = 2k$

$$\hat{T}_t = \frac{1}{2m} X_{t-k} + \frac{1}{m} X_{t-k+1} + \cdots + \frac{1}{m} X_{t+k-1} + \frac{1}{2m} X_{t+k}$$

- s rostoucím m se odhadnutá křivka vyhlazuje! (tj. šířka vyhlazovacího okénka)





- Box-Jenkinsonova metodologie
- pro stacionární NP
- spojení
 - autoregresních NP (AR) a
 - NP klouzavých průměrů (MA) tj. autoregressive–moving-average models
- ARMA(p, q): $X_t - \varphi_1 X_{t-1} - \dots - \varphi_p X_{t-p} = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$
- integrovaná ARMA = ARIMA, tj. ARMA(p, d, q)
- sezonní ARMA = SARMA, tj. ARMA(p, q)(P, Q) $_s$
- SARIMA, tj. ARMA(p, d, q)(P, D, Q) $_s$
Např. ARMA(0, 1, 1)(0, 1, 1) $_{12}$

$$X_t = X_{t-1} + X_{t-12} - X_{t-13} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_1^* \varepsilon_{t-12} + \theta_1 \theta_1^* \varepsilon_{t-13}$$

- Přednášky: M9121 Časové řady I
- Pravděpodobně i přednášky M0122 Časové řady II $\sim \setminus (\ominus) _ / \sim$
- Skripta: <https://www.math.muni.cz/~vondra/uvn/vystupy/KA1/M5201/M5201.pdf>