

Náhodné procesy II

Zuzana Prášková¹

¹Katedra pravděpodobnosti a matematické statistiky
Univerzita Karlova v Praze
email: praskova@karlin.mff.cuni.cz

25. a 26. 2. 2010



Literatura

Definice a
základní
charakteristiky

Definice procesu

Daniel-
Kolmogorovova
věta

Autokovarianční
a autokorelační
funkce

Striktní a slabá
stacionarita

Vlastnosti
autokovarianční
funkce

Některé
důležité třídy
náhodných
procesů

Markovovy
procesy

Procesy
s nezávislými
přírůstky

Literatura

Definice a
základní
charakteristiky

Definice procesu
Daniel-
Kolmogorovova
věta

Autokovarianční
a autokorelační
funkce

Striktní a slabá
stacionarita
Vlastnosti
autokovarianční
funkce

Některé
důležité třídy
náhodných
procesů

Markovovy
procesy

Procesy
s nezávislými
přírůstky

Základní literatura:

Z. Prášková: Základy náhodných procesů II, Karolinum 2006

Rozšiřující literatura:

Brockwell, P. J., Davis, R. A.: Time Series: Theory and Methods. Springer-Verlag, New York 1991

Anděl, J.: Statistická analýza časových řad. SNTL, Praha 1976

Literatura

Definice a
základní
charakteristiky

Definice procesu

Daniel-
Kolmogorovova
věta

Autokovarianční
a autokorelační
funkce

Striktní a slabá
stacionarita

Vlastnosti
autokovarianční
funkce

Některé
důležité třídy
náhodných
procesů

Markovovy
procesy

Procesy
s nezávislými
přírůstky

Definice a základní charakteristiky

Definice:

Nechť (Ω, \mathcal{A}, P) je pravděpodobnostní prostor, nechť $T \subset \mathbb{R}$. Rodina reálných náhodných veličin $\{X_t, t \in T\}$ definovaných na (Ω, \mathcal{A}, P) se nazývá **náhodný proces**.

Poznámka:

$T = \mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$ nebo $T \subset \mathbb{Z}$ - **proces s diskrétním časem, časová řada**

$T = [a, b], -\infty \leq a < b \leq \infty$ - $\{X_t, t \in T\}$ je **proces se spojitým časem**.

Definice:

Dvojice (S, \mathcal{E}) , kde S je množina hodnot náhodných veličin X_t a \mathcal{E} je σ -algebra podmnožin S , se nazývá **stavový prostor** procesu $\{X_t, t \in T\}$. Pokud náhodné veličiny X_t nabývají pouze diskrétních hodnot, říkáme, že jde o **proces s diskrétními stavy**, nabývají-li hodnot z nějakého intervalu, mluvíme o **procesu se spojitými stavy**.

Definice:

Reálný stochastický proces $\{X_t, t \in T\}$ se nazývá **měřitelný**, jestliže zobrazení $(\omega, t) \rightarrow X_t(\omega)$ je $\mathcal{A} \otimes \mathcal{B}_T$ -měřitelné, kde \mathcal{B}_T je σ -algebra borelovských podmnožin T a $\mathcal{A} \otimes \mathcal{B}_T$ značí součinovou σ -algebru.

konečně-rozměrná rozdělení:

$\forall n \in \mathbb{N}_0$ a každé konečné podmnožině $\{t_1, \dots, t_n\} \subset T$ lze přiřadit systém náhodných veličin X_{t_1}, \dots, X_{t_n} , které mají sdružené rozdělení s distribuční funkcí

$$\mathbb{P}[X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n] = F_{t_1, \dots, t_n}(x_1, \dots, x_n)$$

pro všechna x_1, \dots, x_n .

Systém distribučních funkcí se nazývá **konzistentní**, jestliže platí

- $F_{t_{i_1}, \dots, t_{i_n}}(x_{i_1}, \dots, x_{i_n}) = F_{t_1, \dots, t_n}(x_1, \dots, x_n)$ pro každou permutaci (i_1, \dots, i_n) z $(1, \dots, n)$.
- $\lim_{x_n \rightarrow \infty} F_{t_1, \dots, t_n}(x_1, \dots, x_n) = F_{t_1, \dots, t_{n-1}}(x_1, \dots, x_{n-1})$.

Systém **charakteristických funkcí** odpovídající F_{t_1, \dots, t_n} :

Je-li $\mathbf{X} = (X_1, \dots, X_n)$ náhodný vektor, pak charakteristická funkce má tvar

$$\varphi(\mathbf{u}) := Ee^{i\mathbf{u}^\top \mathbf{X}} = Ee^{i \sum_{j=1}^n u_j X_j}, \quad \mathbf{u} = (u_1, \dots, u_n).$$

- $F_{t_1, \dots, t_n}(x_1, \dots, x_n) \leftrightarrow \varphi(u_1, \dots, u_n),$
- **symetrie:**

$$\varphi(u_{i_1}, \dots, u_{i_n}) = \varphi(u_1, \dots, u_n)$$

pro lib. permutaci $(i_1, \dots, i_n) \in (1, \dots, n)$,

- **konzistence:**

$$\lim_{u_n \rightarrow 0} \varphi_{X_{t_1}, \dots, X_{t_n}}(u_1, \dots, u_n) = \varphi_{X_{t_1}, \dots, X_{t_{n-1}}}(u_1, \dots, u_{n-1}).$$

Daniel-Kolmogorovova věta

Ke každému náhodnému procesu existuje konzistentní systém distribučních funkcí. Naopak platí

Věta 0:

Nechť $\{F_{t_1, \dots, t_n}(x_1, \dots, x_n)\}$ je konzistentní systém distribučních funkcí. Potom existuje náhodný proces $\{X_t, t \in T\}$ takový, že pro každé $n \in \mathbb{N}$, libovolná $t_1, \dots, t_n \in T$ a libovolná reálná x_1, \dots, x_n platí

$$P[X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n] = F_{t_1, \dots, t_n}(x_1, \dots, x_n).$$

Důkaz: Štěpán (1987), věta I.10.3.

Definice:

Komplexní náhodná veličina X se definuje jako $X = Y + iZ$, kde Y a Z jsou reálné náhodné veličiny.

Pokud existují střední hodnoty EY a EZ , definujeme střední hodnotu komplexní náhodné veličiny X jako

$$EX = EY + iEZ.$$

Existují-li druhé momenty náhodných veličin Y a Z , definujeme rozptyl náhodné veličiny X jako

$$\text{var } X := E[(X - EX)(\bar{X} - \bar{EX})] = E|X - EX|^2,$$

což je vždy nezáporné číslo.

Definice:

Komplexní náhodný proces je definován jako rodina komplexních náhodných veličin na (Ω, \mathcal{A}, P) .

Definice:

Nechť $\{X_t, t \in T\}$ je náhodný proces takový, že pro každé $t \in T$ existuje střední hodnota $E X_t$. Potom funkce $\mu_t = E X_t$ definovaná na T se nazývá **střední hodnota procesu** $\{X_t, t \in T\}$. Proces, jehož střední hodnota je identicky rovna nule, se nazývá **centrovaný**.

Definice:

Jestliže $\{X_t, t \in T\}$ je proces s konečnými druhými momenty, tj. $E|X_t|^2 < \infty, \forall t \in T$, potom (obecně komplexní) funkce dvou proměnných definovaná na $T \times T$ předpisem

$$R(s, t) = E [(X_s - \mu_s)(\bar{X}_t - \bar{\mu}_t)]$$

se nazývá **autokovarianční funkce** procesu $\{X_t, t \in T\}$. Hodnota $R(t, t)$ se nazývá **rozptyl** procesu v čase t .

Definice:

Autokorelační funkce procesu $\{X_t, t \in T\}$ s kladnými rozptyly je definována jako

$$r(s, t) = \frac{R(s, t)}{\sqrt{R(s, s)} \sqrt{R(t, t)}}, \quad s, t \in T.$$

Definice:

Náhodný proces $\{X_t, t \in T\}$ se nazývá **gaussovský (normální)**, jsou-li všechna jeho konečněrozměrná rozdělení normální, tj. jestliže pro každé $n \in \mathbb{N}$ a $t_1, \dots, t_n \in T$ má vektor $(X_{t_1}, \dots, X_{t_n})^\top$ n -rozměrné normální rozdělení $\mathcal{N}_n(\mathbf{m}_t, \mathbf{V}_t)$, kde $\mathbf{m}_t = (\mathbb{E}X_{t_1}, \dots, \mathbb{E}X_{t_n})^\top$ a

$$\mathbf{V}_t = \begin{pmatrix} \text{var}X_{t_1} & \text{cov}(X_{t_1}, X_{t_2}) & \dots & \text{cov}(X_{t_1}, X_{t_n}) \\ \text{cov}(X_{t_2}, X_{t_1}) & \text{var}X_{t_2} & \dots & \text{cov}(X_{t_2}, X_{t_n}) \\ \dots & \dots & \ddots & \dots \\ \text{cov}(X_{t_n}, X_{t_1}) & \text{cov}(X_{t_n}, X_{t_2}) & \dots & \text{var}X_{t_n} \end{pmatrix}.$$

Definice:

Řekneme, že náhodný proces $\{X_t, t \in T\}$ je **striktně stacionární**, jestliže pro libovolné $n \in \mathbb{N}$, pro libovolná reálná x_1, \dots, x_n a pro libovolná t_1, \dots, t_n a h taková, že $t_k \in T, t_k + h \in T, 1 \leq k \leq n$, platí

$$F_{t_1, \dots, t_n}(x_1, \dots, x_n) = F_{t_1+h, \dots, t_n+h}(x_1, \dots, x_n).$$

Definice:

Náhodný proces $\{X_t, t \in T\}$ s konečnými druhými momenty se nazývá **slabě stacionární**, má-li konstantní střední hodnotu $\mu_t = \mu$, $\forall t \in T$ a je-li jeho autokovarianční funkce $R(s, t)$ funkcí pouze $s - t$. Je-li splněna pouze podmínka na autokovarianční funkci, mluvíme o **kovarianční stacionaritě**.

Autokovarianční funkce slabě stacionárních procesů:

$$R(t) := R(t, 0), \quad t \in T,$$

(funkce jedné proměnné).

Rozptyl stacionárního procesu : $\text{var } X_t = R(t - t) = R(0)$

Autokorelační funkce je potom dána předpisem

$$r(t) = \frac{R(t)}{R(0)}.$$

Věta 1:

Striktně stacionární náhodný proces $\{X_t, t \in T\}$ s konečnými druhými momenty je i slabě stacionární.

Důkaz:

$\{X_t, t \in T\}$ striktně stacionární $\Rightarrow X_t$ mají pro všechna $t \in T$ stejné rozdělení a tedy stejnou konečnou střední hodnotu

$$\mathbb{E}X_t = \mathbb{E}X_{t+h}, \quad \forall t \in T, \forall h : t + h \in T$$

$$\text{speciálně pro } h = -t : \mathbb{E}X_t = \mathbb{E}X_0 = \text{konst}$$

Důkaz Věty 1, pokr.

Podobně (X_t, X_s) a (X_{t+h}, X_{s+h}) mají stejné sdružené rozdělení
a tedy

$$E[X_t X_s] = E[X_{t+h} X_{s+h}] \quad \forall s, t \in T, \forall h : s+h \in T, t+h \in T$$

speciálně pro $h = -t$: $E[X_t X_s] = E[X_0 X_{s-t}]$
je funkce $s - t$. □

Příklad:

$\{X_t, t \in T\}$ posloupnost iid náhodných veličin s distribuční funkcí F

$$\begin{aligned} F_{t_1, \dots, t_n}(x_1, \dots, x_n) &= P[X_{t_1} \leq x_1, \dots, X_{t_n} \leq x_n] = \\ &= \prod_{i=1}^n P[X_{t_i} \leq x_i] = \prod_{i=1}^n F(x_i), \end{aligned}$$

$$\begin{aligned} F_{t_1+h, \dots, t_n+h}(x_1, \dots, x_n) &= P[X_{t_1+h} \leq x_1, \dots, X_{t_n+h} \leq x_n] = \\ &= \prod_{i=1}^n P[X_{t_i+h} \leq x_i] = \prod_{i=1}^n F(x_i), \end{aligned}$$

$\Rightarrow \{X_t, t \in T\}$ je striktně stacionární.

Příklad:

Posloupnost $\{X_t, t \in \mathbb{Z}\}$ definovaná předpisem

$$X_t = (-1)^t X,$$

kde X je náhodná veličina:

$$X = \begin{cases} -\frac{1}{4} & \text{s pravděpodobností } \frac{3}{4}, \\ \frac{3}{4} & \text{s pravděpodobností } \frac{1}{4}. \end{cases}.$$

Pak $\{X_t, t \in \mathbb{Z}\}$ je slabě stacionární, neboť

$$\mathbb{E}X_t = 0,$$

$$\text{var } X_t = \sigma^2 = \frac{3}{16},$$

$$R(s, t) = \sigma^2(-1)^{s+t} = \sigma^2(-1)^{s-t},$$

ale není striktně stacionární (veličiny X a $-X$ mají různé rozdělení).

Věta 2:

Slabě stacionární gaussovský proces $\{X_t, t \in T\}$ je i striktně stacionární.

Důkaz:

Ze slabé stacionarity procesu $\{X_t, t \in T\}$ plyne

$E X_t = \mu, \text{cov}(X_t, X_s) = R(t-s) = \text{cov}(X_{t+h}, X_{s+h}), t, s \in T,$
tedy

$$E(X_{t_1}, \dots, X_{t_n}) = \boldsymbol{\mu} = (\mu, \dots, \mu) = E(X_{t_1+h}, \dots, X_{t_n+h})$$

$$\text{var}(X_{t_1}, \dots, X_{t_n}) = \boldsymbol{\Sigma} = \text{var}(X_{t_1+h}, \dots, X_{t_n+h})$$

Literatura

Definice a
základní
charakteristiky

Definice procesu

Daniel-
Kolmogorovova
věta

Autokovarianční
a autokorelační
funkce

Striktní a slabá
stacionarita

Vlastnosti
autokovarianční
funkce

Některé
důležité třídy
náhodných
procesů

Markovovy
procesy

Procesy
s nezávislými
přírůstky

$$\Sigma = \begin{pmatrix} R(0) & R(t_2 - t_1) & \dots & R(t_n - t_1) \\ R(t_2 - t_1) & R(0) & \dots & R(t_n - t_2) \\ \vdots & \vdots & \ddots & \vdots \\ & & \dots & R(0) \end{pmatrix}.$$

Protože normální rozdělení je určeno jednoznačně vektorem středních hodnot a varianční maticí, $(X_{t_1}, \dots, X_{t_n}) \sim \mathcal{N}(\mu, \Sigma)$, a $(X_{t_1+h}, \dots, X_{t_n+h}) \sim \mathcal{N}(\mu, \Sigma) \Rightarrow \{X_t, t \in T\}$ je striktně stacionární. □

Základní vlastnosti autokovarianční funkce.

Věta 3:

Nechť $\{X_t, t \in T\}$ je proces s konečnými druhými momenty. Potom pro jeho autokovarianční funkci platí

$$R(t, t) \geq 0,$$

$$|R(s, t)| \leq \sqrt{R(s, s)} \sqrt{R(t, t)}.$$

Důkaz:

První vlastnost je vlastnost rozptylu. Druhá vlastnost plyně ze Schwarzovy nerovnosti, neboť

$$\begin{aligned} |R(s, t)| &= |\mathbb{E}(X_s - \mathbb{E}X_s)(\overline{X}_t - \overline{\mathbb{E}X_t})| \leq \mathbb{E}|(X_s - \mathbb{E}X_s)(\overline{X}_t - \overline{\mathbb{E}X_t})| \\ &\leq (\mathbb{E}|X_s - \mathbb{E}X_s|^2)^{\frac{1}{2}} (\mathbb{E}|X_t - \mathbb{E}X_t|^2)^{\frac{1}{2}} = \sqrt{R(s, s)} \sqrt{R(t, t)} \end{aligned}$$



Pro slabě stacionární proces je tedy $R(0) \geq 0$ a $|R(t)| \leq R(0)$.

Definice:

Nechť $f(s, t)$ je obecně komplexní funkce definovaná na $T \times T$, $T \subset \mathbb{R}$. Řekneme, že f je **pozitivně semidefinitní**, jestliže $\forall n \in \mathbb{N}$, libovolná komplexní čísla c_1, \dots, c_n a libovolné body $t_1, \dots, t_n \in T$ platí

$$\sum_{j=1}^n \sum_{k=1}^n c_j \overline{c_k} f(t_j, t_k) \geq 0.$$

Říkáme, že komplexní funkce g jedné proměnné na T je **pozitivně semidefinitní**, jestliže $\forall n \in \mathbb{N}$, libovolná komplexní čísla c_1, \dots, c_n a libovolné body $t_1, \dots, t_n \in T$, takové že $t_j - t_k \in T$, platí

$$\sum_{j=1}^n \sum_{k=1}^n c_j \overline{c_k} g(t_j - t_k) \geq 0.$$

Definice:

Řekneme, že komplexní funkce f na $T \times T$ je **hermitovský symetrická**, jestliže $f(s, t) = \overline{f(t, s)}$ $\forall s, t \in T$. Komplexní funkce g jedné proměnné se nazývá **hermitovský symetrická**, když $\forall t \in T$ je $g(-t) = \overline{g(t)}$.

Věta 4:

Pozitivně semidefinitní funkce je i hermitovský symetrická.

Důkaz:

V definici pozitivní semidefinitnosti pro $n = 1$ stačí zvolit $c_1 = 1$; pro $n = 2$ stačí zvolit $c_1 = 1, c_2 = 1$ a dále $c_1 = 1, c_2 = i (= \sqrt{-1})$. □

Poznámka:

Reálná funkce f dvou proměnných na $T \times T$, která je pozitivně semidefinitní, je symetrická, tj. $f(s, t) = f(t, s)$ pro všechny body $s, t \in T$. Pro reálnou funkci g jedné proměnné na T z pozitivní semidefinitnosti plyne $g(t) = g(-t)$ pro každé $t \in T$.

Věta 5:

Nechť $\{X_t, t \in T\}$ je proces s konečnými druhými momenty. Potom jeho autokovarianční funkce je pozitivně semidefinitní na $T \times T$.

Důkaz:

Bez újmy na obecnosti předpokládejme, že proces je centrováný. Potom pro každé $n \in \mathbb{N}$, komplexní konstanty c_1, \dots, c_n a body $t_1, \dots, t_n \in T$ platí

$$\begin{aligned} 0 \leq E \left| \sum_{j=1}^n c_j X_{t_j} \right|^2 &= E \left[\sum_{j=1}^n c_j X_{t_j} \overline{\sum_{k=1}^n c_k X_{t_k}} \right] \\ &= \sum_{j=1}^n \sum_{k=1}^n c_j \overline{c_k} E(X_{t_j} \overline{X_{t_k}}) = \sum_{j=1}^n \sum_{k=1}^n c_j \overline{c_k} R(t_j, t_k). \end{aligned}$$



Věta 6:

Ke každé pozitivně semidefinitní funkci R na $T \times T$ existuje náhodný proces $\{X_t, t \in T\}$ s konečnými druhými momenty takový, že R je jeho autokovarianční funkcí.

Důkaz:

Větu dokážeme pouze pro reálnou funkci R . Důkaz pro obecnou pozitivně semidefinitní funkci lze nalézt např. v Loèeve (1955), kap. X, odst. 34.

Z pozitivní semidefinitnosti funkce R plyne, že pro každé $n \in \mathbb{N}$ a libovolná reálná čísla $t_1, \dots, t_n \in T$ je matici

$$\mathbf{V}_t = \begin{pmatrix} R(t_1, t_1) & R(t_1, t_2) & \dots & R(t_1, t_n) \\ R(t_2, t_1) & R(t_2, t_2) & \dots & R(t_2, t_n) \\ \vdots & \vdots & \ddots & \vdots \\ R(t_n, t_1) & R(t_n, t_2) & \dots & R(t_n, t_n) \end{pmatrix}$$

pozitivně semidefinitní.

Důkaz Věty 6, pokr.

Funkce

$$\varphi(\mathbf{u}) = \exp\left\{-\frac{1}{2}\mathbf{u}^\top \mathbf{V}_t \mathbf{u}\right\}, \quad \mathbf{u} \in \mathbb{R}^n$$

je charakteristickou funkcí normálního rozdělení $\mathcal{N}_n(\mathbf{0}, \mathbf{V}_t)$.
 $\forall n \in \mathbb{N}$ a libovolná reálná čísla $t_1, \dots, t_n \in T$ takto vytvoříme systém charakteristických funkcí, jemuž odpovídá systém normálních distribučních funkcí, který je konzistentní. Tudíž podle Daniellovy-Kolmogorovovy věty existuje gaussovský náhodný proces, jehož všechny vzájemné kovariance jsou určeny hodnotami funkce $R(s, t)$; funkce R je tedy jeho autokovarianční funkce. □

Příklad:

Zjistěte, zda je funkce $\cos t$, $t \in T = (-\infty, \infty)$ autokovarianční funkcí nějakého náhodného procesu.

Řešení:

Stačí ověřit, že funkce $\cos t$ je pozitivně semidefinitní. Nechť je $n \in \mathbb{N}$, $c_1, \dots, c_n \in \mathbb{C}$ a $t_1, \dots, t_n \in \mathbb{R}$. Potom platí

$$\begin{aligned} \sum_{j=1}^n \sum_{k=1}^n c_j \bar{c}_k \cos(t_j - t_k) &= \sum_{j=1}^n \sum_{k=1}^n c_j \bar{c}_k (\cos t_j \cos t_k + \sin t_j \sin t_k) \\ &= \left| \sum_{j=1}^n c_j \cos t_j \right|^2 + \left| \sum_{k=1}^n c_k \sin t_k \right|^2 \geq 0. \end{aligned}$$

Funkce $\cos t$ je tedy pozitivně semidefinitní, a proto podle věty 6 existuje (gaussovský) náhodný proces $\{X_t, t \in T\}$, jehož autokovarianční funkce je $R(s, t) = \cos(s - t)$.

Věta 7:

Součet dvou pozitivně semidefinitních funkcí je pozitivně semidefinitní funkce.

Důkaz:

Tvrzení plyne z definice pozitivně semidefinitní funkce, neboť jsou-li funkce f a g pozitivně semidefinitní a $h = f + g$, platí pro každé $n \in \mathbb{N}$, komplexní konstanty c_1, \dots, c_n a body $t_1, \dots, t_n \in T$

$$\begin{aligned} \sum_{j=1}^n \sum_{k=1}^n c_j \bar{c}_k h(t_j, t_k) &= \sum_{j=1}^n \sum_{k=1}^n c_j \bar{c}_k [f(t_j, t_k) + g(t_j, t_k)] \\ &= \sum_{j=1}^n \sum_{k=1}^n c_j \bar{c}_k f(t_j, t_k) + \sum_{j=1}^n \sum_{k=1}^n c_j \bar{c}_k g(t_j, t_k) \geq 0. \end{aligned}$$



Důsledek:

Součet dvou autokovariančních funkcí je autokovarianční funkce nějakého náhodného procesu s konečnými druhými momenty.

Důkaz:

Tvrzení je jednoduchým důsledkem vět 5, 6 a 7. □

Věta 8:

Reálná část autokovarianční funkce je také autokovarianční funkci. Imaginární část je autokovarianční funkci jen tehdy, je-li identicky rovná nule.

Důkaz:

Bez újmy na obecnosti dokážeme tvrzení jen pro centrované procesy. Je-li $X_t = Y_t + iZ_t$ komplexní proces s nulovou střední hodnotou, pak $EY_t = EZ_t = 0$ a

$$R(s, t) = EX_s \bar{X}_t = E[(Y_s + iZ_s)(Y_t - iZ_t)] =$$

$EY_s Y_t + EZ_s Z_t + i(EZ_s Y_t - EY_s Z_t)$. Reálná část je autokovarianční funkci podle předchozího důsledku. Protože pro $s = t$ je imaginární část nulová, platí i druhé tvrzení. □

Literatura

Definice a
základní
charakteristiky

Definice procesu

Daniel-
Kolmogorovova
věta

Autokovarianční
a autokorelační
funkce

Striktní a slabá
stacionarita

Vlastnosti
autokovarianční
funkce

Některé
důležité třídy
náhodných
procesů

Markovovy
procesy

Procesy
s nezávislými
přírůstky

Některé důležité třídy náhodných procesů

Markovovy procesy

Definice:

Řekneme, že proces $\{X_t, t \in T\}$ je Markovův proces se stavovým prostorem (S, \mathcal{E}) , jestliže pro libovolné $t_0, t_1, \dots, t_n, 0 \leq t_0 < t_1 < \dots < t_n$, platí

$$P(X_{t_n} \leq x | X_{t_{n-1}}, \dots, X_{t_0}) = P(X_{t_n} \leq x | X_{t_{n-1}}) \text{ s. j. } (1)$$

pro každé $x \in \mathbb{R}$.

Vlastnost (1) se nazývá **markovská vlastnost**. Jednoduchými případy jsou Markovovy procesy s diskrétními stavy, neboli Markovovy řetězce s diskrétním a spojitém časem.

Příklad:

Markovův řetězec $\{X_t, t \geq 0\}$ s množinou stavů $S = \{0, 1\}$, s počátečním rozdělením $P(X_0 = 0) = 1, P(X_0 = 1) = 0$ a maticí intenzit

$$\mathbf{Q} = \begin{pmatrix} -\alpha & \alpha \\ \beta & -\beta \end{pmatrix}, \quad \alpha > 0, \beta > 0$$

Zkoumejme stacionaritu tohoto procesu.

Víme:

$$\mathbf{p}(t)^T = \mathbf{p}(0)^T \mathbf{P}(t) = (1, 0) \mathbf{P}(t) = (p_{00}(t), p_{01}(t))$$

$$\mathbf{P}(t) = \frac{1}{\alpha + \beta} \begin{pmatrix} \beta + \alpha e^{-(\alpha+\beta)t} & \alpha - \alpha e^{-(\alpha+\beta)t} \\ \beta - \beta e^{-(\alpha+\beta)t} & \alpha + \beta e^{-(\alpha+\beta)t} \end{pmatrix}.$$

Příklad, pokr.

Nyní máme vzhledem k počátečnímu rozdělení

$$P(X_t = 1) = p_{01}(t) = EX_t = \frac{1}{\alpha + \beta} \cdot \left(\alpha - \alpha e^{-(\alpha + \beta)t} \right),$$

což závisí na t , proces tedy není striktně, ani slabě stacionární.

Pokud ale počáteční rozdělení je stacionární rozdělení daného Markovova řetězce, potom $\{X_t, t \geq 0\}$ je striktně stacionární proces se střední hodnotou $EX_t = \frac{\alpha}{\alpha + \beta}$ a autokovarianční funkcí

$$R(s, t) = \frac{\alpha\beta}{(\alpha + \beta)^2} e^{-(\alpha + \beta)|s-t|}.$$

Je tedy i slabě stacionární.

Příklad, pokr.

Důk.

stacionární rozdělení: $\pi^T = \pi^T \mathbf{P}(t)$

lze řešit jako $\pi^T \mathbf{Q} = \mathbf{0}^T$

$$\pi_0 = \frac{\beta}{\alpha+\beta}, \pi_1 = \frac{\alpha}{\alpha+\beta}$$

ze stacionarity: $\mathbf{p}(t) = \pi \Rightarrow E X_t = P(X_t = 1) = \frac{\alpha}{\alpha+\beta}$

pro $t < s$,

$$\begin{aligned} E(X_t X_s) &= 1 \cdot P(X_t = 1, X_s = 1) \\ &= P(X_s = 1 | X_t = 1) P(X_t = 1) \\ &= p_{11}(s - t) P(X_t = 1) \end{aligned}$$

Procesy s nezávislými přírůstky

Definice:

Řekneme, že proces $\{X_t, t \in T\}$, kde T je interval, má **nezávislé přírůstky**, jestliže pro každé $t_1, t_2, \dots, t_n \in T$ s vlastností $t_1 < t_2 < \dots < t_n$ jsou náhodné veličiny $X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}}$ nezávislé.

Jestliže pro každé $s, t \in T$, $s < t$, rozdělení přírůstku $X_t - X_s$ závisí pouze na $t - s$, řekneme, že proces $\{X_t, t \in T\}$ má **stacionární přírůstky**.

Př. Poissonův proces s intenzitou λ je Markovův řetězec $\{X_t, t \geq 0\}$ se spojitým časem takový, že $X_0 = 0$ s.j. a pro $t > 0$ mají náhodné veličiny X_t Poissonovo rozdělení s parametrem λt . Přírůstky $X_t - X_s$ pro $s < t$ mají Poissonovo rozdělení s parametrem $\lambda(t - s)$. Není stacionární ani ve striktním, ani v slabém smyslu.

Wienerův proces (někdy též nazývaný proces *Brownova pohybu*). Je definován jako gaussovský náhodný proces $\{W_t, t \geq 0\}$ s následujícími vlastnostmi:

- ① $W_0 = 0$ s. j. a $\{W_t, t \geq 0\}$ má spojité trajektorie.
- ② Pro libovolné časové okamžiky $0 \leq t_1 < t_2 < \dots < t_n$ jsou přírůstky $W_{t_1}, W_{t_2} - W_{t_1}, W_{t_3} - W_{t_2}, \dots, W_{t_n} - W_{t_{n-1}}$ nezávislé náhodné veličiny.
- ③ Pro libovolné časové okamžiky $0 \leq t < s$ mají přírůstky $W_s - W_t$ normální rozdělení s nulovou střední hodnotou a rozptylem $\sigma^2(s - t)$, kde σ^2 je kladná konstanta.
Speciálně, pro každé $t \geq 0$ je $E W_t = 0$ a $\text{var } W_t = \sigma^2 t$.

Jak je vidět, ani Wienerův proces není stacionární ve smyslu výše uvedených definic stacionarity.