

Základy náhodných procesů II

Zuzana Prášková

UNIVERZITA KARLOVA
NAKLADATELSTVÍ KAROLINUM

Základy náhodných procesů II

Zuzana Prášková

Recenzovali:

doc. RNDr. Tomáš Čipra, DrSc.

Mgr. David Kraus

Vydala Univerzita Karlova, Nakladatelství Karolinum

jako učební text pro MFF UK

Sazba Zuzana Prášková s použitím typografického systému LaTeX
2., upravené vydání

© Zuzana Prášková, 2016

© Univerzita Karlova, 2016

Text neprošel jazykovou ani redakční úpravou nakladatelství.

ISBN 978-80-246-3516-3

ISBN 978-80-246-3529-3 (online : pdf)



Univerzita Karlova

Nakladatelství Karolinum 2016

www.karolinum.cz

ebooks@karolinum.cz

Obsah

Předmluva	7
Seznam použitých symbolů	8
1 Základní pojmy	9
1.1 Definice a základní charakteristiky náhodného procesu	9
1.1.1 Striktní a slabá stacionarita	11
1.1.2 Vlastnosti autokovarianční funkce	12
1.2 Některé důležité třídy náhodných procesů	15
1.2.1 Markovovy procesy	15
1.2.2 Procesy s nezávislými přírůstky	16
1.2.3 Martingaly	17
1.3 Cvičení a doplňky	17
2 Procesy s konečnými druhými momenty	21
2.1 Hilbertův prostor	21
2.2 Prostor $L_2(\Omega, \mathcal{A}, P)$	22
2.3 Procesy se spojitým časem v $L_2(\Omega, \mathcal{A}, P)$	25
2.3.1 Spojitost procesu	25
2.3.2 Derivace procesu	26
2.3.3 Riemannův integrál	28
2.4 Cvičení a doplňky	29
3 Spektrální rozklad autokovarianční funkce	31
3.1 Pomocná tvrzení	31
3.2 Spektrální rozklad autokovarianční funkce	32
3.3 Existence a výpočet spektrální hustoty	35
3.4 Cvičení a doplňky	39
4 Spektrální rozklad náhodného procesu	41
4.1 Procesy s ortogonálními přírůstky	41
4.2 Integrál podle procesu s ortogonálními přírůstky	42
4.3 Spektrální rozklad stacionárních procesů	47

4.4	Cvičení a doplňky	53
5	Lineární modely časových řad	55
5.1	Posloupnosti klouzavých součtů	55
5.2	Lineární proces	58
5.3	Autoregresní posloupnosti	62
5.4	Posloupnosti ARMA	71
5.5	Lineární filtry	76
5.6	Cvičení a doplňky	78
6	Vybrané limitní věty	81
6.1	Zákony velkých čísel	81
6.2	Centrální limitní věty	86
6.3	Cvičení a doplňky	95
7	Predikce	97
7.1	Predikce v časové doméně	97
7.1.1	Projekce v Hilbertově prostoru	97
7.1.2	Predikce založená na konečné minulosti	99
7.1.3	Rekurzivní postupy pro predikci	103
7.1.4	Predikce založená na nekonečné minulosti	111
7.2	Predikce ve spektrální doméně	114
7.3	Cvičení a doplňky	119
8	Filtrace signálu a šumu	123
8.1	Filtrace v konečné stacionární posloupnosti	123
8.2	Filtrace v nekonečné stacionární posloupnosti	124
8.3	Cvičení a doplňky	129
9	Odhady průměru a autokorelační funkce	131
9.1	Odhad průměru	131
9.2	Odhady autokovarianční a autokorelační funkce	132
9.3	Parciální autokorelační funkce	135
9.4	Cvičení a doplňky	142
10	Odhady parametrů v modelech ARMA	145
10.1	Odhady parametrů v modelech AR	145
10.2	Odhady parametrů v modelech MA a ARMA	149
10.3	Maximálně věrohodné odhady	152
10.4	Cvičení a doplňky	155

11 Periodogram a odhady spektrální hustoty	157
11.1 Periodogram	157
11.2 Odhady spektrální hustoty	163
Literatura	167

Předmluva

Toto je druhé vydání učebního textu k předmětu Náhodné procesy 2 pro posluchače MFF UK, kteří studují magisterský studijní program Matematika ve studijních oborech Finanční a pojistná matematika a Pravděpodobnost, matematická statistika a ekonometrie. Navazuje na učební texty Prášková, Z., Lachout, P.: Základy náhodných procesů (Karolinum, Praha 1998, 2001, 2005) a Prášková, Z., Lachout, P.: Základy náhodných procesů I (Matfyzpress, Praha 2012) k přednášce Náhodné procesy 1.

Výklad látky začíná opakováním základních vlastností náhodných procesů z předchozího kursu, které doplňuje o nové souvislosti, dále však již pokračuje nezávisle a soustředí se na teorii stacionárních procesů s diskrétním i spojitým časem. Předpokládá pokročilejší znalosti z teorie pravděpodobnosti (např. z přednášky Pravděpodobnost 1) a také základní znalosti funkcionální a komplexní analýzy a matematické statistiky (např. Úvod do funkcionální analýzy, Úvod do komplexní analýzy, Matematická statistika 1).

Do tohoto vydání byly zahrnuty některé zkušenosti z výuky, text byl částečně modifikován a rozšířen. Kapitola 11 je zcela nová. Text byl rovněž doplněn o další literaturu.

autorka

Seznam použitých symbolů

\mathbb{N}	množina přirozených čísel
\mathbb{N}_0	množina nezáporných celých čísel
\mathbb{Z}	množina celých čísel
\mathbb{R}	množina reálných čísel
\mathbb{C}	množina komplexních čísel
\mathbf{x}	sloupcový vektor
\mathbf{A}	obecná matice
\mathbf{I}	jednotková matice
$\ \cdot\ $	norma prvku
\mathcal{B}	borelovská σ -algebra
$\mathcal{N}(\mu, \sigma^2)$	normální rozdělení s parametry μ, σ^2
$X \sim \mathcal{N}(\mu, \sigma^2)$	náhodná veličina s rozdělením $\mathcal{N}(\mu, \sigma^2)$
$\{X_t, t \in T\}$	proces náhodných veličin
$\mathcal{M}\{X_t, t \in T\}$	lineární obal procesu $\{X_t, t \in T\}$
$\mathcal{H}\{X_t, t \in T\}$	Hilbertův prostor vytvořený náhodným procesem $\{X_t, t \in T\}$
$X \perp Y$	ortogonální náhodné veličiny
$\overline{\lim}$	limes superior
$\xrightarrow{\text{P}}$	konvergence v pravděpodobnosti
$\xrightarrow{\text{D}}$	konvergence v distribuci
l. i. m.	konvergence podle kvadratického středu

Kapitola 1

Základní pojmy

1.1 Definice a základní charakteristiky náhodného procesu

Definice 1.1. Necht' (Ω, \mathcal{A}, P) je pravděpodobnostní prostor, necht' $T \subset \mathbb{R}$ a (S, \mathcal{E}) je obecný měřitelný prostor. Rodina náhodných veličin $\{X_t, t \in T\}$ definovaných na (Ω, \mathcal{A}, P) s hodnotami v S se nazývá *náhodný proces*.

V případě, že $T = \mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$ nebo $T \subset \mathbb{Z}$, mluvíme o *procesu s diskrétním časem* nebo o *časové řadě*. Pokud $T = [a, b]$, kde $-\infty \leq a < b \leq \infty$, říkáme, že $\{X_t, t \in T\}$ je *proces se spojitým časem*. Pokud $S = \mathbb{R}$, říkáme, že $\{X_t, t \in T\}$ je *reálný náhodný proces*.

Definice 1.2. 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*.

Náhodný proces $\{X_t, t \in T\}$ můžeme chápat jako funkci dvou proměnných ω, t . Pro pevné $t \in T$ je $X_t = X_t(\cdot)$ náhodná veličina definovaná na Ω ; pro pevné $\omega \in \Omega$ je $X_{(\cdot)} = X_{(\cdot)}(\omega)$ funkcí proměnné t . Této funkci říkáme *trajektorie procesu* $\{X_t, t \in T\}$.

Definice 1.3. 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 součinnou σ -algebru.

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

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

Pro $n \in \mathbb{N}$ a $t_1, \dots, t_n \in T$ má systém distribučních funkcí $\{F_{t_1, \dots, t_n}(x_1, \dots, x_n)\}$ následující vlastnosti: Pro libovolnou permutaci i_1, \dots, i_n čísel $1, \dots, n$ platí

$$F_{t_{i_1}, \dots, t_{i_n}}(x_{i_1}, \dots, x_{i_n}) = F_{t_1, \dots, t_n}(x_1, \dots, x_n) \quad (1.1)$$

a

$$\lim_{x_{n+1} \rightarrow \infty} F_{t_1, \dots, t_n, t_{n+1}}(x_1, \dots, x_n, x_{n+1}) = F_{t_1, \dots, t_n}(x_1, \dots, x_n). \quad (1.2)$$

Systém distribučních funkcí s uvedenými vlastnostmi se nazývá *konzistentní*. Ke každému náhodnému procesu existuje konzistentní systém distribučních funkcí. Naopak platí

Věta 1.1 (Daniellova-Kolmogorovova). *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 1.4. *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*

$$\text{var } X = E(X - EX)(\overline{X} - \overline{EX}) = E|X - EX|^2,$$

což je vždy nezáporné číslo.

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

Definice 1.5. *Nechť $\{X_t, t \in T\}$ je náhodný proces takový, že pro každé $t \in T$ existuje střední hodnota EX_t . Potom funkce $\mu_t = EX_t$ definovaná na T se nazývá *střední hodnota procesu* $\{X_t, t \in T\}$. Proces, jehož střední hodnota je identicky rovna nule, se nazývá *centrovaný*.*

Jestliže $\{X_t, t \in T\}$ je proces s konečnými druhými momenty, tj. $E|X_t|^2 < \infty$ pro všechna $t \in T$, potom (obecně komplexní) funkce dvou proměnných definovaná na $T \times T$ předpisem $R(s, t) = E(X_s - \mu_s)(\overline{X_t} - \overline{\mu_t})$ se nazývá *autokovarianční funkce procesu* $\{X_t, t \in T\}$. Hodnota $R(t, t)$ se nazývá *rozptyl procesu* v čase t .

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 1.6. 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 $(X_{t_1}, \dots, X_{t_n})'$ n -rozměrné normální rozdělení $\mathcal{N}_n(\mathbf{m}_t, \mathbf{V}_t)$, kde $\mathbf{m}_t = (EX_{t_1}, \dots, EX_{t_n})'$ a

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

1.1.1 Striktní a slabá stacionarita

Definice 1.7. 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

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

Je-li proces $\{X_t, t \in T\}$ striktně stacionární, pak všechny náhodné veličiny X_t mají stejné rozdělení a základní charakteristiky (střední hodnota, rozptyl, kovariance, ...) se nemění při posunutí v čase. Zavedeme ještě méně přísnou definici stacionarity.

Definice 1.8. Náhodný proces $\{X_t, t \in T\}$ s konečnými druhými momenty se nazývá *slabě stacionární*, má-li konstantní střední hodnotu $\mu_t = \mu$ pro všechna $t \in T$ 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*.

Poznámka 1.1. Autokovarianční funkci slabě stacionárních procesů lze definovat jako funkci jedné proměnné vztahem $R(t) := R(t, 0), t \in T$; autokorelační funkce je potom dána předpisem $r(t) = R(t)/R(0)$.

Věta 1.2. *Striktně stacionární náhodný proces $\{X_t, t \in T\}$ s konečnými druhými momenty je i slabě stacionární.*

Důkaz. Je zřejmé, neboť ze striktní stacionarity plyne, že náhodné veličiny X_t mají pro všechna $t \in T$ stejné rozdělení a tedy stejnou konečnou střední hodnotu a podobně náhodné veličiny X_t a X_{t+h} mají pro všechna $t \in T$ a každé h takové, že $t \in T, t+h \in T$, stejné sdružené rozdělení a tedy stejné kovariance. \square

Opačné tvrzení obecně neplatí; např. posloupnost $\{X_t, t \in \mathbb{Z}\}$ definovaná předpisem $X_t = (-1)^t X$, kde X je náhodná veličina nabývající hodnoty $-\frac{1}{4}$ s pravděpodobností $\frac{3}{4}$ a hodnoty $\frac{3}{4}$ s pravděpodobností $\frac{1}{4}$, je slabě stacionární, neboť $EX_t = 0, \text{var} X_t = \sigma^2 = \frac{3}{16}, R(s, t) = \sigma^2(-1)^{s+t} = \sigma^2(-1)^{s-t}$, ale není striktně stacionární. Platí však

Věta 1.3. *Slabě stacionární gaussovský proces $\{X_t, t \in T\}$ je i striktně stacionární.*

Důkaz. Ze slabé stacionarity procesu $\{X_t, t \in T\}$ plyne, že pro každé $n \in \mathbb{N}$ a libovolné t_1, \dots, t_n, h mají náhodné vektory $(X_{t_1}, \dots, X_{t_n})$ a $(X_{t_1+h}, \dots, X_{t_n+h})$ stejnou střední hodnotu a stejnou (konečnou) varianční matici. Protože normální rozdělení je těmito charakteristikami určeno jednoznačně, musí mít tyto vektory stejné rozdělení. \square

1.1.2 Vlastnosti autokovarianční funkce

Uveďme nyní základní vlastnosti autokovarianční funkce.

Věta 1.4. *Nechť $\{X_t, t \in T\}$ je proces s konečnými druhými momenty. Potom pro jeho autokovarianční funkci platí*

$$\begin{aligned} R(t,t) &\geq 0, \\ |R(s,t)| &\leq \sqrt{R(s,s)}\sqrt{R(t,t)}. \end{aligned}$$

Důkaz. První vlastnost je vlastnost rozptylu. Druhá vlastnost plyne ze Schwarzovy nerovnosti, neboť

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

\square

Poznámka 1.2. Pro slabě stacionární proces je tedy $R(0) \geq 0$ a $|R(t)| \leq R(0)$.

Definice 1.9. Nechť $f(s,t)$ je obecně komplexní funkce definovaná na $T \times T$, $T \subset \mathbb{R}$. Řekneme, že f je *pozitivně semidefinitní*, jestliže pro každé $n \in \mathbb{N}$, libovolná komplexní čísla c_1, \dots, c_n a libovolné body $t_1, \dots, t_n \in T$ platí

$$\sum_{j=1}^n \sum_{k=1}^n c_j \overline{c_k} f(t_j, t_k) \geq 0. \quad (1.3)$$

Říkáme, že komplexní funkce g jedné proměnné na T je *pozitivně semidefinitní*, jestliže pro každé $n \in \mathbb{N}$, 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

$$\sum_{j=1}^n \sum_{k=1}^n c_j \overline{c_k} g(t_j - t_k) \geq 0. \quad (1.4)$$

Definice 1.10. Řekneme, že komplexní funkce f na $T \times T$ je *hermitovskými symetrická*, jestliže $f(s,t) = \overline{f(t,s)}$ pro všechna $s, t \in T$.

Komplexní funkce g jedné proměnné se nazývá *hermitovskými symetrická*, když pro všechna $t \in T$ je $g(-t) = \overline{g(t)}$.

Věta 1.5. *Pozitivně semidefinitní funkce je i hermitovsky symetrická.*

Důkaz. V definici 1.9 pro $n = 1$ stačí zvolit $c_1 = 1$; pro $n = 2$ stačí zvolit $c_1 = 1, c_2 = 1$ a dále $c_1 = 1, c_2 = i (= \sqrt{-1})$. \square

Poznámka 1.3. 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 1.6. *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 přirozené číslo n , komplexní konstanty c_1, \dots, c_n a body $t_1, \dots, t_n \in T$ platí

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

\square

Věta 1.7. *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 Loève (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 matice

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

pozitivně semidefinitní. Funkce $\varphi(\mathbf{u}) = \exp\{-\frac{1}{2}\mathbf{u}'\mathbf{V}_t\mathbf{u}\}$ pro $\mathbf{u} \in \mathbb{R}^n$ je charakteristickou funkcí normálního rozdělení $\mathcal{N}_n(\mathbf{0}, \mathbf{V}_t)$. Pro všechna $n \in \mathbb{N}$ 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-Kolmogorovy věty existuje gaussovský náhodný proces, jehož všechny vzájemné kovariance jsou určeny hodnotami funkce $R(s, t)$; funkce R je tedy jeho autokovarianční funkce. \square

Příklad 1.1. Zjistěte, zda funkce $\cos t$, $t \in T = (-\infty, \infty)$, je autokovarianční funkce 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 1.7 existuje (gaussovský) náhodný proces $\{X_t, t \in T\}$, jehož autokovarianční funkce je $R(s, t) = \cos(s - t)$.

Věta 1.8. *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 $t_1, \dots, t_n \in T$

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

□

Věta 1.9. *Součet dvou autokovariančních funkcí je autokovarianční funkce nějakého náhodného procesu s konečnými druhými momenty.*

Důkaz. Tvrzení je jednoduchým důsledkem vět 1.6, 1.7 a 1.8.

□

Věta 1.10. *Reálná část autokovarianční funkce je také autokovarianční funkcí. Imaginární část je autokovarianční funkcí jen tehdy, je-li identicky rovná nule.*

Důkaz. Bez újmy na obecnosti dokážeme 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 funkcí podle předchozí věty. Protože pro $s = t$ je imaginární část nulová, platí i druhé tvrzení.

□

1.2 Některé důležité třídy náhodných procesů

Stacionární procesy tvoří velmi důležitou třídu náhodných procesů. V následujících kapitolách se budeme zabývat převážně slabě stacionárními procesy. V tomto odstavci se zmíníme ještě o dalších vlastnostech a třídách náhodných procesů.

1.2.1 Markovovy procesy

Definice 1.11. Řekneme, že proces $\{X_t, t \geq 0\}$ 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

$$P(X_{t_n} \leq x | X_{t_{n-1}}, \dots, X_{t_0}) = P(X_{t_n} \leq x | X_{t_{n-1}}) \quad \text{s. j.} \quad (1.5)$$

pro každé $x \in \mathbb{R}$.

Vlastnost (1.5) se nazývá *markovská vlastnost*. Jednoduchými případy jsou Markovovy procesy s diskrétními stavy, neboli Markovovy řetězce s diskrétním a spojitým časem, které jsou popsány např. v Prášková a Lachout (2005) nebo v Prášková a Lachout (2012).

Příklad 1.2. Uvažujme Markovův řetězec $\{X_t, t \geq 0\}$ s množinou stavů $S = \{0, 1\}$ a spojitým časem, jehož počáteční rozdělení je $P(X_0 = 0) = 1, P(X_0 = 1) = 0$, a jehož matice intenzit je

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

$\alpha > 0, \beta > 0$.

Zkoumejme stacionaritu tohoto procesu. Víme, že všechna konečněrozměrná rozdělení daného řetězce jsou dána počátečním rozdělením a soustavou matic pravděpodobností přechodu $\mathbf{P}(t) = \{p_{ij}(t), i, j \in S\}$ pro všechna $t \geq 0$ (Prášková a Lachout, 2012, odst. 3.1). Matice $\mathbf{P}(t)$ jsou v tomto případě tvaru (viz Prášková a Lachout, 2012, příklad 3.4)

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

Nyní máme vzhledem k počátečnímu rozdělení

$$P(X_t = 0) = p_{00}(t) = \frac{1}{\alpha + \beta} (\beta + \alpha e^{-(\alpha+\beta)t}),$$

což závisí na t , a podobně dostaneme $P(X_t = 1) = p_{01}(t) = EX_t$. 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 (věta 3.12 v Prášková a Lachout, 2012) 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.

1.2.2 Procesy s nezávislými přírůstky

Definice 1.12. 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 přírůstků $X_t - X_s$ závisí pouze na $t - s$, řekneme, že proces $\{X_t, t \in T\}$ má *stacionární přírůstky*.

Procesem s nezávislými a stacionárními přírůstky je např. *Poissonův proces* s intenzitou λ , což 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 $\lambda(t - s)$. Podrobněji je Poissonův proces popsán např. v Prášková a Lachout (2012), odst. 3.4.

Jak můžeme snadno nahlédnout, rozdělení přírůstků $X_t - X_s$ závisí skutečně jen na $t - s$. Poissonův proces ale není stacionární ani ve striktním, ani v slabém smyslu.

Jiný důležitý proces s nezávislými a stacionárními přírůstky je *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 spojitě 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 $EW_t = 0$ a $\text{var } W_t = \sigma^2 t$.

Jak je vidět, ani Wienerův proces není stacionární ve smyslu definic z odstavce 1.1.1.

1.2.3 Martingaly

Uvedeme jen základní definice.

Definice 1.13. Nechť (Ω, \mathcal{A}, P) je pravděpodobnostní prostor, nechť $T \subset \mathbb{R}, T \neq \emptyset$. Nechť pro každé $t \in T$ je dána σ -algebra $\mathcal{F}_t \subset \mathcal{A}$. Potom systém σ -algeber $\{\mathcal{F}_t, t \in T\}$ takový, že $\mathcal{F}_s \subset \mathcal{F}_t$ pro každé $s, t \in T, s < t$, se nazývá *filtrace*.

Definice 1.14. Nechť $\{X_t, t \in T\}$ je náhodný proces definovaný na (Ω, \mathcal{A}, P) a nechť $\{\mathcal{F}_t, t \in T\}$ je filtrace. Jestliže náhodná veličina X_t je \mathcal{F}_t -měřitelná pro každé $t \in T$, řekneme, že $\{X_t, t \in T\}$ je *adaptovaný* na $\{\mathcal{F}_t, t \in T\}$.

Definice 1.15. Nechť $\{X_t, t \in T\}$ je náhodný proces adaptovaný na filtraci $\{\mathcal{F}_t, t \in T\}$ a $E|X_t| < \infty$ pro všechna $t \in T$. Tento proces se nazývá *martingal* vzhledem k filtraci $\{\mathcal{F}_t, t \in T\}$, jestliže $E(X_t | \mathcal{F}_s) = X_s$ s. j. pro každé $s < t, s, t \in T$.

Poznámka 1.4. Jestliže $\mathcal{F}_t = \sigma(X_s, s \leq t)$ je σ -algebra generovaná náhodnými veličinami procesu do času t , potom $\{\mathcal{F}_t, t \in T\}$ se nazývá *kanonická* nebo *přirozená* filtrace. Pokud se hovoří jen o martingalu, většinou jde o právě o martingal vzhledem ke kanonické filtraci. Teorii martingalů se zabývá např. učebnice Štěpán (1987).

1.3 Cvičení a doplňky

Cvičení 1.1. Nechť $\{X_t, t \in \mathbb{Z}\}$ je posloupnost nezávislých stejně rozdělených náhodných veličin. Dokažte, že je striktně stacionární. Je také slabě stacionární?

Cvičení 1.2. Nechť $\{X_t, t \in \mathbb{Z}\}$ je posloupnost nekorelovaných náhodných veličin s nulovou střední hodnotou a konečným kladným rozptylem. Dokažte, že je slabě stacionární. Je také striktně stacionární?

Cvičení 1.3. Nechť

$$\begin{aligned} X_0 &= 0 \\ X_t &= Y_1 + \dots + Y_t, \quad t = 1, 2, \dots, \end{aligned}$$

kde Y_1, Y_2, \dots jsou nezávislé, stejně rozdělené náhodné veličiny s nulovou střední hodnotou a konečným kladným rozptylem. Dokažte, že posloupnost $\{X_t, t \in \mathbb{N}_0\}$ je Markovův řetězec. Spočítejte autokovarianční funkci této posloupnosti. Co lze říci o striktní, resp. slabé stacionaritě této náhodné posloupnosti ?

Cvičení 1.4. Rozhodněte o stacionaritě posloupnosti $\{X_t, t \in \mathbb{Z}\}$ definované pro každé t předpisem

$$X_t = a + bY_t + cY_{t-1},$$

kde a, b, c jsou konstanty a Y_t jsou nezávislé náhodné veličiny s normovaným normálním rozdělením.

Cvičení 1.5. Nechť $X_t = a + bt + Y_t, t \in \mathbb{Z}$, kde $Y_t, t \in \mathbb{Z}$ jsou nezávislé stejně rozdělené náhodné veličiny s nulovou střední hodnotou a konečným kladným rozptylem, $a, b \in \mathbb{R}$ jsou konstanty. Definujme náhodné veličiny V_t předpisem

$$V_t = \frac{1}{2q+1} \sum_{j=-q}^q X_{t+j}.$$

Spočtěte střední hodnotu a autokovarianční funkci procesu $\{V_t, t \in \mathbb{Z}\}$.

Cvičení 1.6. Uvažujme posloupnost náhodných veličin $\{Y_t, t \in \mathbb{Z}\}$, kde $Y_t = \cos(tX)$, X je náhodná veličina s rovnoměrným rozdělením na intervalu $[0, \pi]$. Spočtěte střední hodnotu a autokovarianční funkci posloupnosti $\{Y_t, t \in \mathbb{Z}\}$.

Cvičení 1.7. Dokažte podrobněji větu 1.5.

Cvičení 1.8. Nechť R_1, R_2 jsou autokovarianční funkce slabě stacionárních procesů a $a > 0, b > 0$. Pak $aR_1 + bR_2$ je opět autokovarianční funkce nějakého slabě stacionárního procesu. Dokažte.

Cvičení 1.9. Nechť $\{X_t, t \in T\}$ a $\{Y_t, t \in T\}$, kde $T = \mathbb{R}$ nebo $T = \mathbb{Z}$, jsou vzájemně nekorelované slabě stacionární procesy, tj. pro každé $s, t \in T$ jsou X_s, Y_t nekorelované náhodné veličiny. Dokažte, že potom také $\{Z_t, t \in T\}$, kde $Z_t = X_t + Y_t$, je slabě stacionární proces.

Cvičení 1.10. Nechť $\{X_t, t \in T\}$, kde $T = \mathbb{R}$ nebo $T = \mathbb{Z}$, je gaussovský stacionární proces s nulovou střední hodnotou. Dokažte, že potom také $\{Y_t, t \in T\}$, kde $Y_t = X_t^2$, je (slabě i striktně) stacionární proces se střední hodnotou $R_X(0)$ a autokovarianční funkcí $R_Y(s, t) = 2R_X^2(s - t)$.

Návod: Užijte vztahu pro momenty sdruženého normálního rozdělení s nulovou střední hodnotou:

$$E[X_1 X_2 X_3 X_4] = E[X_1 X_2]E[X_3 X_4] + E[X_1 X_3]E[X_2 X_4] + E[X_1 X_4]E[X_2 X_3].$$

Cvičení 1.11. Spočtěte podrobně střední hodnotu a autokovarianční funkci z příkladu 1.2, když počáteční rozdělení Markovova řetězce je stacionární.

Cvičení 1.12. Dokažte, že autokovarianční funkce Poissonova procesu s intenzitou λ je $R(s, t) = \lambda \min(s, t), s, t \geq 0$.

Cvičení 1.13. Spočtete autokovarianční funkci Wienerova procesu a pro $0 \leq t_1 < t_2 \cdots < t_n$ určete varianční matici náhodného vektoru $(W_{t_1}, \dots, W_{t_n})'$.

Cvičení 1.14. Ornsteinův-Uhlenbeckův proces $\{U_t, t \geq 0\}$ je transformace Wienerova procesu

$$U_t = e^{-\frac{\alpha t}{2}} W_{\exp\{\alpha t\}}, \quad \alpha > 0, \quad t \geq 0,$$

kde W_τ je veličina Wienerova procesu v čase τ , $W_\tau \sim \mathcal{N}(0, \sigma^2 \tau)$. Dokažte, že $\{U_t, t \geq 0\}$ je centrovaný striktně stacionární gaussovský proces s autokovarianční funkcí

$$R(s, t) = \sigma^2 \exp\left\{-\frac{\alpha}{2} |t - s|\right\}.$$

Cvičení 1.15. Rozhodněte, zda funkce

$$R(t) = \exp\{\lambda(e^{it} - 1)\}, \quad \lambda > 0, \quad t \in \mathbb{R},$$

je autokovarianční funkce nějakého náhodného procesu.

Cvičení 1.16. Necht' $\{X_n, n \in \mathbb{N}\}$ je posloupnost nezávislých stejně rozdělených náhodných veličin s nulovou střední hodnotou. Označme $S_n = \sum_{k=1}^n X_k$. Potom $\{S_n, n \in \mathbb{N}\}$ tvoří martingal, tj. $E(S_{n+1} | S_1, S_2, \dots, S_n) = S_n$ pro každé $n \in \mathbb{N}$. Dokažte.

Cvičení 1.17. Necht' $\{X_n, n \in \mathbb{N}\}$ je posloupnost martingalových diferencí, tj. pro každé $n \in \mathbb{N}$ je $E|X_n| < \infty$ a $E(X_{n+1} | X_1, X_2, \dots, X_n) = 0$. Potom $X_n, n \in \mathbb{N}$, jsou nekorelované náhodné veličiny. Dokažte, že posloupnost $\{S_n, n \in \mathbb{N}\}$, kde $S_n = \sum_{k=1}^n X_k$, tvoří martingal.

