

# Stochastické procesy ve finanční matematice

Martin Kolář

## Osnova:

náhodná procházka

generující funkce

Polyova věta a zákon arcsinu

Poissonův proces

Cramér-Lundbergův model

Diskrétní modely oceňování finančních derivátů

Základní věta arbitrážní teorie, úplnost trhu

Brownův pohyb

Itôovo lemma a Black-Scholesova rovnice pro oceňování opcí

# Motivace

- Matematické modely ve financích jsou *stochastické*.
- Základní nástroj: *teorie pravděpodobnosti*.

## Příklad:

$X_{12102020}$  ... cena akcie firmy Apple příští pondělí na konci obchodování

Dnes ... cena je neznámá a modelujeme ji jako *náhodnou veličinu*.

Příští týden v pátek ... cena je známou hodnotou (konstantou).

Pro matematické modelování ve financích je typická tato interakce náhodných a známých veličin.

Vzájemnému působení náhodnosti a plynutí času se věnuje **teorie stochastických procesů**.

Systém náhodných veličin  $X_t$ ,  $t \in I$ , kde  $I$  je indexová množina, se nazývá **stochastický proces**.

**Příklad:**  $X_t$  ... cena zvolené akcie v budoucím čase  $t$ .

*Jaký je vztah mezi  $X_t$  a  $X_{t+1}$ ? Mohou to být nezávislé náhodné veličiny?*

Hodnota  $X_t$  obsahuje informaci o pravděpodobnostním rozdělení náhodné veličiny  $X_{t+1}$ .

*Jak je to s přírůstky  $X_{t+2} - X_{t+1}$  a  $X_{t+1} - X_t$ ?*

Ve většině našich modelů budou *nezávislé*.

Souvisí s tzv. **hypotézou efektivního trhu**.

“Všechny informace dostupné v čase  $t$  jsou již obsaženy v ceně  $X_t$ .”

Důsledek: geometrický Brownův pohyb je “přirozeným ” modelem vývoje cen akcií.

# Pravděpodobnost

Teorie pravděpodobnosti je hlavním nástrojem modelování ve finanční matematice.

*Co je to pravděpodobnost?*

**Frekventistický přístup:**

Pravděpodobnost jevu je *limita jeho relativní četnosti* při velkém počtu opakování téhož experimentu.

Nevýhoda: omezení na *opakovatelné jevy*.

Předpoklad opakovatelnosti konkrétní situace na trhu není úplně reálný.



## Bayesovský přístup:

Pravděpodobnost vyjadřuje *míru naší nejistoty* o pravdivosti nějakého tvrzení, založenou na informacích, které v danou chvíli máme.

Každá pravděpodobnost je tedy *podmíněná* (informacemi, které právě máme).

Pravděpodobnost padnutí šestky na kostce je  $P(X = 6) = \frac{1}{6}$ , pokud nemáme žádnou informaci o tom, jak je kostka vyrobena.

Budeme-li mít více informací, může se tato pravděpodobnost změnit.

Matematická technika výpočtů nicméně na interpretaci ve většině případů *nezávisí* a je stejná pro obě pojetí.

# Opakování základních pojmů teorie pravděpodobnosti

Pravděpodobnostní prostor (model) obvykle označujeme  $(\Omega, \mathcal{A}, P)$ ,  
kde

- $\Omega$  je prostor elementárních jevů, t.j. všech možných stavů modelovaného systému, *které chceme rozlišovat* (např.  $\{1, 2, 3, 4, 5, 6\}$  u hodu kostkou).
- $\mathcal{A}$  je množina všech *pozorovatelných jevů*. Prvky  $\mathcal{A}$  jsou podmnožiny  $\Omega$ .

Jev je tedy formálně vzato množina elementárních jevů, které *jsou s ním slučitelné*.

Například jev “padne sudé číslo” je množina  $\{2, 4, 6\}$

Je-li  $\Omega$  konečná nebo spočetná (tak tomu bude u všech diskrétních modelů), je  $\mathcal{A}$  v definici pravděpodobnostního prostoru nadbytečné, neboť automaticky  $\mathcal{A}$  je rovno  $\exp \Omega$ , *množině všech podmnožin  $\Omega$* .

–  $P : \mathcal{A} \rightarrow \langle 0, 1 \rangle$  je **pravděpodobnostní míra**. V diskrétním případě stačí znát hodnoty této míry na elementárních jevech.

Tedy  $P : \Omega \rightarrow \langle 0, 1 \rangle$ .  $P(\omega)$  je pak pravděpodobnost elementárního jevu  $\omega$  a pro obecný jev  $A \in \mathcal{A}$  platí

$$P(A) = \sum_{\omega \in A} P(\omega).$$

Pokud je ale  $\Omega$  nespočetná, pak  $\exp \Omega$  má příliš velkou mohutnost, aby se na ní dala definovat pravděpodobnostní míra. Musíme se pak omezit na menší  $\sigma$ -algebru. S tím se setkáme až u spojitých modelů.

## Diskrétní náhodné proměnné

Diskrétní náhodná proměnná (náhodná veličina) je funkce

$$X : \Omega \rightarrow \{x_1, x_2, \dots\} \subseteq \mathbb{R},$$

kde  $\{x_1, x_2, \dots\}$  je diskrétní podmnožina  $\mathbb{R}$ .

**Definice 1.1.** *Pravděpodobnostní funkce* náhodné veličiny  $X$  je definována jako

$$f(x) = P(X = x).$$

**Definice 1.2.** *Distribuční funkce* náhodné veličiny  $X$  je

$$F(x) = P(X \leq x).$$

Připomeňme si ještě definici nezávislosti dvou jevů.

**Definice 1.3.** Jevy  $A, B \subseteq \Omega$  jsou **nezávislé**, jestliže

$$P(A \cap B) = \frac{P(A \cap B)}{P(B)},$$

tedy

$$P(A \cap B) = P(A)P(B).$$

Jinak řečeno nastal-li jev  $B$ , *nezmění* to pravděpodobnost jevu  $A$ .

**Definice 1.4.** Diskrétní náhodné veličiny  $X$  a  $Y$  jsou *nezávislé*, jestliže jevy  $\{X = x\}$  a  $\{Y = y\}$  jsou nezávislé pro všechna  $x$  a  $y$ . Jinými slovy, znalost hodnoty  $X$  nedává žádnou informaci o hodnotě  $Y$ .

Pravděpodobnostní funkce obsahuje všechny informace o uvažované náhodné veličině. Často nám ale stačí její *číselné charakteristiky*.

**Definice 1.5.** *Očekávání* (střední hodnota) náhodné veličiny  $X$  s pravděpodobnostní funkcí  $f(x)$  je definována jako

$$E(X) = \sum_{x: f(x) > 0} xf(x),$$



Očekávání můžeme vypočítat také pomocí vztahu

$$E(X) = \sum_{\omega \in \Omega} X(\omega)P(\omega).$$

**Definice 1.6.** Je-li  $k$  přirozené číslo,  $k$ -tý *moment*  $m_k$  náhodné veličiny  $X$  je definován jako

$$m_k = E(X^k).$$

**Definice 1.7.**  $k$ -tý *centrální moment*  $\sigma_k$  je definován jako

$$\sigma_k = E((X - m_1)^k).$$

Speciálně,

$$m_1 = E(X)$$

je *střední hodnota* a

$$\sigma_2 = E((X - E(X))^2)$$

je *rozptyl* (variance). Tedy  $\sigma_2 = \sigma^2$ , kde  $\sigma = \sqrt{\sigma_2}$  je střední směrodatná odchylka.

**Definice 1.8.** Necht'  $A$  je jev, tj.  $A \subseteq \Omega$ , a necht'  $I_A : \Omega \rightarrow \mathbb{R}$  je náhodná veličina definovaná vztahem

$$I_A(\omega) = \begin{cases} 1 & \text{pro } \omega \in A \\ 0 & \text{pro } \omega \notin A \end{cases}.$$

Pak  $I_A$  se nazývá *indikátorová funkce* jevu  $A$ .

Libovolnou náhodnou veličinu můžeme zapsat pomocí indikátorových funkcí jevů  $A_i = \{X = x_i\}$ . Máme

$$X = \sum_i x_i I_{A_i}.$$

$I_A$  je Bernoulliiovská náhodná veličina. Nabývá jen hodnot 0 a 1.

## Závislost a nezávislost náhodných veličin

**Lemma 1.9.** *Nechť  $X$  a  $Y$  jsou nezávislé náhodné veličiny. Potom*

$$E(XY) = E(X)E(Y).$$

**Důkaz:** Označme  $A_x = \{X = x\}$  a  $B_y = \{Y = y\}$ . Pak

$$XY = \sum_{x,y} xy I_{A_x \cap B_y},$$

tedy

$$E(XY) = \sum_{x,y} xy E(I_{A_x \cap B_y}) = \sum_{x,y} xy P(A_x \cap B_y) =$$

$$\sum_{x,y} xy P(A_x) P(B_y) = \left( \sum_x x P(A_x) \right) \left( \sum_y y P(B_y) \right) = E(X) E(Y).$$

Opak obecně neplatí.

**Definice 1.10.** Říkáme, že náhodné veličiny  $X$  a  $Y$  jsou *nekorelované*, jestliže platí:

$$E(XY) = E(X)E(Y).$$

**Věta 1.11.** *Necht'  $X$  a  $Y$  jsou náhodné veličiny. Pak*

—  $\text{Var}(aX) = a^2 \text{Var}(X)$  pro  $a \in \mathbb{R}$ .

— *Jsou-li  $X$  a  $Y$  nekorelované (speciálně nezávislé) náhodné veličiny, pak*

$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y).$$

**Definice 1.12.** *Kovariance* náhodných veličin  $X$  a  $Y$  je definována jako

$$\text{cov}(X, Y) = E [(X - E(X))(Y - E(Y))].$$

*Korelační koeficient*  $X$  a  $Y$  je

$$\rho(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}.$$

Platí:

$$\rho(X, Y) = 0 \Leftrightarrow E(XY) = E(X)E(Y) \Leftrightarrow \text{cov}(X, Y) = 0$$

a

$$\text{cov}(X, Y) = E(XY) - E(X)E(Y).$$

Dále je

$$|\rho(X, Y)| \leq 1.$$



*Jak ověřit nezávislost dvou daných náhodných veličin?*

Definice k tomu většinou vhodná není.

**Definice 1.13.** Necht'  $X$  a  $Y$  jsou diskrétní náhodné veličiny (na stejném pravděpodobnostním prostoru). *Sdružená distribuční funkce*  $X$  a  $Y$  je definovaná vztahem

$$F_{X,Y}(x,y) = P(X \leq x \wedge Y \leq y).$$

**Definice 1.14.** *Sdružená pravděpodobnostní funkce:*

$f_{X,Y} : \mathbb{R}^2 \rightarrow [0, 1]$  je definovaná vztahem

$$f_{X,Y}(x, y) = P(X = x \wedge Y = y).$$

Analogicky se definuje sdružená pravděpodobnostní funkce pro více náhodných veličin. Následující lemma dává dobře ověřitelné kritérium nezávislosti.

**Lemma 1.15.** *Diskrétní náhodné veličiny  $X$  a  $Y$  jsou nezávislé právě tehdy, když*

$$f_{X,Y}(x, y) = f_X(x)f_Y(y)$$

*pro všechna  $x, y \in \mathbb{R}$ .*

Ze znalosti sdružené pravděpodobnostní funkce  $f_{X,Y}$  můžeme vypočítat *marginální pravděpodobnostní funkce*  $f_X$  a  $f_Y$ . Máme

$$\begin{aligned} f_X(x) &= P(X = x) = P\left(\bigcup_y (\{X = x\} \cap \{Y = y\})\right) \\ &= \sum_y P(X = x \wedge Y = y) = \sum_y f_{X,Y}(x, y). \end{aligned}$$

**Příklad 1.16.** Necht'  $X : \Omega \rightarrow \{1, 2, 3\}$  a  $Y : \Omega \rightarrow \{-1, 0, 2\}$  jsou náhodné veličiny a sdružená pravděpodobnostní funkce je dána tabulkou:

	$y = -1$	$y = 0$	$y = 2$	$f_X$
$x = 1$	$\frac{1}{18}$	$\frac{3}{18}$	$\frac{2}{18}$	$\frac{6}{18}$
$x = 2$	$\frac{2}{18}$	0	$\frac{3}{18}$	$\frac{5}{18}$
$x = 3$	0	$\frac{4}{18}$	$\frac{3}{18}$	$\frac{7}{18}$
$f_Y$	$\frac{3}{18}$	$\frac{7}{18}$	$\frac{8}{18}$	$\frac{18}{18}$

*Jsou  $X$  a  $Y$  nezávislé?*

Zřejmě ne, v tom případě by řádky tabulky musely být násobkem jeden druhého.

Vypočteme kovarianci těchto dvou náhodných veličin. Máme

$$XY : \Omega \rightarrow \{-1, 0, -2, -3, 2, 4, 6\}.$$

Dále

$$E(X) = \frac{6}{18} + \frac{10}{18} + \frac{21}{18} = \frac{37}{18}, \quad E(Y) = \frac{13}{18}$$

a

$$E(XY) = -1 \frac{1}{18} + 2 \frac{2}{18} - 2 \frac{2}{18} + 4 \frac{3}{18} + 6 \frac{3}{18} = \frac{29}{18}$$

Celkem tedy

$$\text{cov}(X, Y) = E(XY) - E(X)E(Y) = \frac{29}{18} - \frac{481}{324} = \frac{522 - 481}{324} = \frac{41}{324}.$$