

# Obsah

<b>1</b>	<b>Spojité náhodné veličiny a stochastické procesy</b>	<b>3</b>
1.1	Stochastické procesy . . . . .	3
1.2	Spojité náhodné veličiny . . . . .	4
1.2.1	Nezávislost a její charakterizace . . . . .	5
1.2.2	Příklady spojitých rozdělení . . . . .	7
<b>2</b>	<b>Poissonův proces</b>	<b>9</b>
2.1	Základní vlastnosti Poissonova procesu . . . . .	9
<b>3</b>	<b>Charakteristická funkce a její vlastnosti</b>	<b>13</b>
3.1	Charakteristická funkce . . . . .	13
3.2	Základní vlastnosti Fourierovy transformace . . . . .	15
3.3	Základy $L^2$ -teorie . . . . .	20
3.4	Borel-Cantelliho lemma . . . . .	23
<b>4</b>	<b>Wienerův proces</b>	<b>25</b>
4.1	Definice Wienerova procesu . . . . .	25
4.2	Haarovy a Schauderovy funkce . . . . .	25
4.3	Ciesielskiho konstrukce . . . . .	28
<b>5</b>	<b>Lineární a kvadratická variace</b>	<b>33</b>
5.1	Lineární variace . . . . .	33
5.2	Kvadratická variace . . . . .	35
<b>6</b>	<b>Itôův integrál a Itôovo lemma</b>	<b>38</b>
6.1	Itôův integrál . . . . .	38
6.2	Filtrace . . . . .	40
6.3	Itôovo lemma . . . . .	44
<b>7</b>	<b>Martingaly a Itôovy procesy</b>	<b>48</b>
7.1	Definice martingalu . . . . .	48
7.2	Itôův proces a stopping time . . . . .	50

<b>8</b>	<b>Cameron-Martinova věta</b>	<b>52</b>
8.1	Radon-Nikodýmova derivace . . . . .	52
8.2	Cameron-Martinova věta . . . . .	53
8.3	Girsanovova věta . . . . .	55
<b>9</b>	<b>Odvození Black-Scholesovy rovnice</b>	<b>57</b>
9.1	Black-Scholesova rovnice . . . . .	58
<b>10</b>	<b>Black-Scholesův model</b>	<b>60</b>
10.1	Předpoklady Black-Scholesova modelu . . . . .	60
10.2	Odvození ceny evropské call opce . . . . .	61
10.3	Odvození Black-Scholesova vzorce pro evropskou call opci . . .	62
<b>11</b>	<b>Rovnice vedení tepla a Wienerův proces</b>	<b>65</b>
11.1	Řešení rovnice vedení tepla na přímce . . . . .	65
11.2	Souvislost řešení rovnice vedení tepla a Wienerova procesu . .	66
11.3	Feynman-Kacova formule . . . . .	67
<b>12</b>	<b>Bariérové opce</b>	<b>69</b>
12.1	Binární bariérové opce . . . . .	69

# Kapitola 1

## Spojité náhodné veličiny a stochastické procesy

### 1.1 Stochastické procesy

**Definice 1.1.1.** *Stochastický proces*  $X = \{X(t), t \in T\}$  je soubor náhodných veličin na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$ .

Tedy pro každé  $t$  z indexové množiny  $T$  je  $X(t)$  náhodná veličina. Obvykle  $t$  označuje čas. Připomeňme, že náhodná veličina je funkce  $Z : \Omega \rightarrow \mathbb{R}$ .

Každá realizace náhodného procesu  $X$  se nazývá **trajektorie**.  $X(t)$  popisuje stav procesu v čase  $t$ .

#### Dělení stochastických procesů:

- je-li  $T$  konečná nebo spočetná množina, říkáme, že  $X(t)$  je stochastický proces v diskrétním čase
- je-li  $T$  interval, říkáme, že  $X(t)$  je stochastický proces ve spojitém čase

Další rozdělení podle hodnot, které nabývají veličiny  $X(t)$ :

- stochastický proces s diskrétními hodnotami
- stochastický proces se spojitými hodnotami

Celkem tedy máme následující čtyři typy stochastických procesů:

čas	hodnoty	příklady
diskrétní	diskrétní	standardní náhodná procházka
diskrétní	spojité	zobecněná náhodná procházka
spojitý	diskrétní	Poissonův proces
spojitý	spojité	Wienerův proces, bílý šum

Uveďme si příklad Poissonova procesu (podrobněji viz následující kapitola).

Nechť  $X(t)$  je počet volání na telefonní ústřednu v časovém intervalu  $[0, t]$ . Předpokládáme, že

$$P(X(t+h) - X(t) = 1) \approx \lambda h$$

t.j. pravděpodobnost, že v intervalu  $(t, t+h)$  přišlo jedno volání je přímo úměrná  $h$ , a dále

$$P(X(t+h) - X(t) > 1) \approx 0.$$

Koeficient úměrnosti  $\lambda$  popisuje intenzitu procesu.

**Stochastická analýza** je integrální počet pro funkce, jejichž hodnoty jsou závislé na Wienerově procesu.

Například, nechť  $f(X, t)$  je cena opce v čase  $t$  při ceně podkladové akcie  $X$ , pro kterou platí

$$\frac{dX}{X} = a dt + b dW$$

kde  $W$  je standardní Wienerův proces (přesným smyslem této rovnice se budeme zabývat v dalších kapitolách). Hodnota  $f$  tedy zprostředkovaně závisí na hodnotě Wienerova procesu.

## 1.2 Spojité náhodné veličiny

Nechť  $(\Omega, \mathcal{A}, P)$  je pravděpodobnostní prostor modelující uvažovaný systém.

**Definice 1.2.1.**  $X : \Omega \rightarrow \mathbb{R}$  je spojitá náhodná veličina, jestliže její distribuční funkce  $F(x) = P(X \leq x)$  se dá napsat jako

$$F(x) = \int_{-\infty}^x f(u) du$$

pro nějakou integrovatelnou funkci  $f : \mathbb{R} \rightarrow [0, \infty)$ .  $f(u)$  se nazývá (pravděpodobnostní) *hustota* náhodné veličiny  $X$ .

Máme

$$P(X \in [x, x + \Delta x]) \doteq f(x) \Delta x$$

a

$$P(X \in [a, b]) = \int_a^b f(u) du.$$

Pro každé jednotlivé  $x \in \mathbb{R}$  tedy platí

$$P(X = x) = 0.$$

**Poznámka.** Mnoho důkazů pro spojité náhodné veličiny je zcela analogických jako v diskrétním případě. Pravděpodobnostní funkce  $f(x)$  se nahradí hustotou  $f(x) dx$ , a suma  $\sum$  se nahradí integrálem  $\int$ .

### 1.2.1 Nezávislost a její charakterizace

**Definice 1.2.2.** Náhodné veličiny  $X$  a  $Y$  jsou **nezávislé**, jestliže pro každé  $x, y \in \mathbb{R}$  jsou jevy  $\{X \leq x\}$  a  $\{Y \leq y\}$  nezávislé.

Základní charakteristikou náhodné veličiny je její očekávání.

**Definice 1.2.3. Očekávání** spojité náhodné veličiny  $X$  s hustotou  $f$  je dáno vztahem

$$E(X) = \int_{-\infty}^{\infty} f(x) x dx$$

pokud integrál existuje.

**Příklad 1.2.4.** Nechť pro hustotu náhodné veličiny  $X$  platí  $f(x) = \frac{1}{2\pi}$  pro  $x \in [0, 2\pi]$  a  $f(x) = 0$  jinak. Její očekávání je rovno

$$E(X) = \int_{-\infty}^{\infty} f(x) x dx = \int_0^{2\pi} \frac{1}{2\pi} x dx = \frac{1}{2\pi} \left[ \frac{x^2}{2} \right]_0^{2\pi} = \pi.$$

Při praktickém výpočtu očekávání funkce náhodné veličiny je důležitá následující věta.

**Věta 1.2.5.** Nechť  $X$  je spojitá náhodná veličina s hustotou  $f(x)$  a  $g(x)$  je spojitá funkce. Pak pro náhodnou veličinu  $g(X)$  platí

$$E(g(X)) = \int_{-\infty}^{\infty} g(x) f(x) dx.$$

**Definice 1.2.6.** Sdružená distribuční funkce náhodných veličin  $X$  a  $Y$  je funkce  $\mathbb{R}^2 \rightarrow [0, 1]$  taková, že

$$F(x, y) = P(X \leq x \wedge Y \leq y).$$

**Definice 1.2.7.** Náhodné veličiny  $X$  a  $Y$  mají *sdrúženou pravděpodobnostní hustotu*  $f(x, y) : \mathbb{R}^2 \rightarrow [0, \infty)$ , jestliže

$$F(x, y) = \int_{-\infty}^y \int_{-\infty}^x f(u, v) \, du \, dv$$

pro všechna  $x, y \in \mathbb{R}$ .

Analogicky jako u obyčejné hustoty máme

$$P\{(X, Y) \in (x, x + \Delta x) \times (y, y + \Delta y)\} \approx f(x, y) \Delta x \Delta y.$$

**Definice 1.2.8.** *Marginální distribuční funkce*  $X$  a  $Y$  jsou

$$F_X(x) = P(X \leq x) = F(x, \infty),$$

kde  $F(x, \infty) = \lim_{y \rightarrow \infty} F(x, y)$  a

$$F_Y(y) = P(Y \leq y) = F(\infty, y),$$

kde  $F(\infty, y) = \lim_{x \rightarrow \infty} F(x, y)$ .

Pro *marginální hustoty* platí:

$$f_X(x) = \int_{-\infty}^{\infty} f(x, y) \, dy,$$

$$f_Y(y) = \int_{-\infty}^{\infty} f(x, y) \, dx.$$

Následující věta dává ověřitelnou podmínku pro nezávislost náhodných veličin.

**Věta 1.2.9.** *Náhodné veličiny  $X, Y$  jsou nezávislé právě tehdy, když pro každé  $x, y \in \mathbb{R}$  platí*

$$f(x, y) = f_X(x) f_Y(y).$$

## 1.2.2 Příklad y spojité y rozdělení

**Uniformní (stejnomyěrné) rozdělení:** Náhodná veličina  $X$  je stejnoměrná na intervalu  $[a, b]$ , jestliže

$$f(x) = \frac{1}{b-a}$$

pro  $x \in [a, b]$  a  $f(x) = 0$  jinak.

**Normální rozdělení:** Náhodná veličina  $X$  má normální rozdělení, jestliže

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

pro  $x \in (-\infty, \infty)$ , kde  $\mu$  je střední hodnota a  $\sigma^2$  je rozptyl.

Normalizované normální rozdělení  $N(0, 1)$  má hustotu

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}.$$

Hodnota normalizační konstanty plyne z hodnoty tzv. Laplaceova integrálu:

**Lemma 1.2.10.** Platí

$$\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = 1.$$

**Důkaz:** Označme

$$I = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx.$$

Uvažujme druhou mocninu integrálu

$$I^2 = \left( \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx \right) \left( \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} dy \right) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{-\frac{x^2+y^2}{2}} dx dy.$$

Transformujeme integrál do polárních souřadnic,

$$I^2 = \frac{1}{2\pi} \int_0^{2\pi} \int_0^{\infty} e^{-\frac{r^2}{2}} r dr d\theta = \frac{1}{2\pi} \int_0^{2\pi} 1 d\theta = \frac{1}{2\pi} 2\pi = 1,$$

protože substitucí  $t = -\frac{r^2}{2}$  dostaneme

$$\int_0^{\infty} r e^{-\frac{r^2}{2}} dr = \int_0^{-\infty} -e^t dt = \int_{-\infty}^0 e^t dt = [e^t]_{-\infty}^0 = 1.$$

Odtud plyne  $I = 1$ .

**2-rozměrné (standardizované) normální rozdělení:** Dvojice náhodných veličin  $X, Y$  má toto rozdělení pokud pro jeho sdruženou hustotu platí

$$f(x, y) = \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)}(x^2 - 2\rho xy + y^2)\right),$$

kde  $\rho$  je korelace  $X$  a  $Y$ , splňující  $-1 \leq \rho \leq 1$ . Přímým výpočtem dostaneme

$$f_X(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$

a

$$f_Y(y) = \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}}.$$

Pro  $\rho = 0$  tedy platí

$$f(x, y) = \frac{1}{2\pi} e^{-\frac{1}{2}(x^2+y^2)} = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} \frac{1}{\sqrt{2\pi}} e^{-\frac{y^2}{2}} = f_X(x) f_Y(y).$$

Odtud plyne důležitá charakteristika nezávislosti normálně rozdělených náhodných veličin.

**Věta 1.2.11.** *Normálně rozdělené náhodné veličiny  $X$  a  $Y$  jsou nezávislé právě tehdy když jsou nekorelované, t.j.  $\rho = 0$ .*

Toto tvrzení je klíčové pro praktické ověřování nezávislosti náhodných veličin s normálním rozdělením. Obecně je nezávislost daleko silnější vlastnost než nekorelovanost.



# Kapitola 2

## Poissonův proces

### 2.1 Základní vlastnosti Poissonova procesu

**Definice 2.1.1.** *Poissonův proces* s intenzitou  $\lambda$  je proces  $N = \{N(t) : t \geq 0\}$  nabývající hodnoty v  $S = \{0, 1, 2, \dots\}$  takový, že

1.  $N(0) = 0$  a pro  $s < t$  je  $N(s) < N(t)$ .

$$2. P(N(t+h) = n+m | N(t) = n) = \begin{cases} \lambda h + o(h) & \text{pro } m = 1 \\ o(h) & \text{pro } m > 1. \\ 1 - \lambda h + o(h) & \text{pro } m = 0 \end{cases}$$

3. Je-li  $s < t$ , pak počet  $N(t) - N(s)$  událostí v intervalech  $[s, t]$  je nezávislý na  $N(s)$ , t.j. počtu událostí v  $[0, s]$ .

$N(t) \dots$  počet příchodů, událostí, emisí do času  $t$ .

$N$  je tzv. počítací proces a je také příkladem Markovovského řetězce ve spojitém čase.

Zajímá nás rozložení  $N(t)$ .

**Věta 2.1.2.**  $N(t)$  má Poissonovo rozdělení s parametrem  $\lambda t$ , tedy

$$P(N(t) = j) = \frac{(\lambda t)^j}{j!} e^{-\lambda t}, \quad j = 0, 1, 2, \dots$$

*Důkaz.* Podmíníme  $N(t+h)$  na  $N(t)$ :

$$\begin{aligned}
P(N(t+h) = j) &= \sum_i P(N(t) = i) \cdot P(N(t+h) = j | N(t) = i) \\
&= \sum_i P(N(t) = i) P((j-i) \text{ příchodů v čase } (t, t+h)) \\
&= P(N(t) = j-1) \cdot P(1 \text{ příchod}) + P(N(t) = j) \cdot P(\text{žádný příchod}) + o(h).
\end{aligned}$$

Tedy  $p_j(t) = P(N(t) = j)$  splňuje

$$\begin{aligned}
p_j(t+h) &= \lambda h p_{j-1}(t) + (1 - \lambda h) \cdot p_j(t) + o(h) \quad \text{pro } j \neq 0 \\
p_0(t+h) &= (1 - \lambda h) \cdot p_0(t) + o(h).
\end{aligned}$$

V první rovnici odečteme  $p_j(t)$ , vydělíme  $h$  a necháme  $h \rightarrow 0$ . Pak

$$p'_j(t) = \lambda p_{j-1}(t) - \lambda p_j(t) \quad \text{pro } j \neq 0 \quad (2.1)$$

a podobně z 2. rovnice

$$p'_0(t) = -\lambda p_0(t).$$

Okrajové podmínky jsou

$$p_j(0) = \delta_{j0} = \begin{cases} 1 & \text{pro } j = 0 \\ 0 & \text{pro } j \neq 0. \end{cases}$$

To je systém diferenčně-diferenciálních rovnic pro  $p_j(t)$ .

Řešení najdeme pomocí generujících funkcí (v proměnné  $s$  a s parametrem  $t$ ).

Definujeme

$$G(s, t) = \sum_0^{\infty} p_j(t) s^j = \mathcal{F}(s^{N(t)}).$$

Rovnici 2.1 vynásobíme  $s^j$  a sečteme přes  $j$ . Dostaneme

$$\frac{\partial G}{\partial t} = \lambda(s-1)G$$

s okrajovou podmínkou  $G(s, 0) = 1$ . Řešení je zřejmě

$$G(s, t) = e^{\lambda(s-1)t} = e^{-\lambda t} \sum_0^{\infty} \frac{(\lambda t)^j}{j!} s^j$$

□

Uvedeme si ještě důležitou alternativní definici.

**Definice 2.1.3.** Necht'  $T_0, T_1, \dots$  jsou dány vztahem

$$T_0 = 0, \quad T_n = \inf\{t : N(t) = n\}.$$

Pak  $T_n$  se nazývá čas  $n$ -tého příchodu.

**Definice 2.1.4.** Definujeme časy mezi příchody (*Inter-arrival times*) jako náhodné veličiny

$$X_n = T_n - T_{n-1}.$$

Ze znalosti  $N(t)$  umíme najít hodnoty  $X_n$ . Naopak z  $X_n$  lze zrekonstruovat  $N(t)$  pomocí

$$T_n = \sum_1^n X_i; \quad N(t) = \max\{n; T_n \leq t\}.$$

**Věta 2.1.5.** *Náhodné veličiny  $X_1, X_2, \dots$  jsou nezávislé a mají exponenciální rozdělení s parametrem  $\lambda$ .*

**Připomenutí:** Náhodná veličina  $X$  má exponenciální rozdělení s parametrem  $\lambda > 0$ , jestliže její distribuční funkce je

$$F(x) = 1 - e^{-\lambda x} \quad x \geq 0 \tag{2.2}$$

Uvažujme Bernoulliho pokusy v časech  $\delta, 2\delta, 3\delta, \dots$  a necht'  $W$  je čas čekání na 1. úspěch. Pak

$$P(W > k\delta) = (1 - p)^k \quad \text{a} \quad EW = \frac{\delta}{p}.$$

Zvolme  $t$  pevně. Do času  $t$  jsme udělali přibližně  $k = \frac{t}{\delta}$  pokusů. Necht'  $\delta \rightarrow 0$ . Abychom dostali netriviální limitu, musí také  $p \rightarrow 0$ . Necht'  $\frac{p}{\delta} \rightarrow \lambda$ . Pak

$$P(W > t) = P\left(W > \left(\frac{t}{\delta}\right) \cdot \delta\right) \cong (1 - \lambda\delta)^{\frac{t}{\delta}} \rightarrow e^{-\lambda t}$$

*Důkaz.* Nejdřív uvažujeme  $X_1$ :

$$P(X_1 > t) = P(N(t) = 0) = e^{-\lambda t}.$$

Dále podmíníme  $X_2$  na  $X_1$ ,

$$P(X_2 > t | X_1 = t_1) = P(\text{žádný příchod v } [t_1, t_1 + t] | X_1 = t_1).$$

Událost  $\{X_1 = t_1\}$  se vztahuje k intervalu  $[0, t_1]$ , zatímco událost "žádný příchod v  $[t_1, t_1 + t]$ " k času  $> t_1$ . Z definice Poissonova procesu jsou nezávislé, tedy

$$P(X_2 > t | X_1 = t_1) = P(\text{žádný příchod v } [t_1, t_1 + t]) = e^{-\lambda t}.$$

Tedy  $X_2$  je nezávislá na  $X_1$  a má stejné rozdělení. Podobně pro  $X_n$ , indukci přes  $n$ .  $\square$

# Kapitola 3

## Charakteristická funkce a její vlastnosti

### 3.1 Charakteristická funkce

**Připomenutí:** *Generující funkce* pro diskrétní náhodnou veličinu s hodnotami v  $\mathbb{N}$ ,  $X : \Omega \rightarrow \mathbb{N}$  je definována jako

$$G_X(s) = \sum_{n=0}^{\infty} f(n) s^n = E(s^X),$$

kde  $f(n) = P(X = n)$  je pravděpodobnostní funkce  $X$ .

Obecněji můžeme definovat (substitucí  $s = e^t$ ) moment generující funkci, i pro spojité náhodné veličiny.

**Definice 3.1.1.** *Moment generující funkce* náhodné veličiny  $X$  je definována vztahem

$$M(t) = E(e^{tX})$$

pro  $t \geq 0$ .

Je-li  $X$  spojitá náhodná veličina s hustotou  $f$ , pak

$$M(t) = \int_{-\infty}^{\infty} e^{tx} f(x) dx.$$

Až na obor integrace a znaménko v exponentu je to přesně *Laplaceova transformace* funkce  $f$  (u Laplaceovy transformace se integruje jen přes kladnou poloosu).

Moment generující funkce dovoluje snadno počítat jednotlivé momenty náhodných veličin. Pro střední hodnotu máme

$$E(X) = M'(0).$$

Obecně platí následující tvrzení.

**Lemma 3.1.2.** *Pro každé  $k \in \mathbb{N}$  je*

$$E(X^k) = M^{(k)}(0).$$

**Důkaz:** Derivujeme integrál podle parametru,

$$M'(t) = \int_{-\infty}^{\infty} x e^{tx} f(x) dx,$$

tedy

$$M'(0) = \int_{-\infty}^{\infty} x f(x) dx = E(X).$$

Analogicky  $k$ -násobným derivováním dostaneme

$$M^{(k)}(t) = \int_{-\infty}^{\infty} x^k e^{tx} f(x) dx.$$

Tedy

$$M^{(k)}(0) = E(X^k).$$

Charakteristická funkce se formálně liší od moment generující funkce jen imaginární jednotkou v exponentu. Výhodou je že na rozdíl od moment generující funkce existuje pro libovolnou pravděpodobnostní hustotu.

**Definice 3.1.3.** *Charakteristická funkce náhodné veličiny  $X$  je funkce  $\phi : \mathbb{R} \rightarrow \mathbb{C}$  definovaná vztahem*

$$\phi(t) = E(e^{itX}).$$

Je-li  $f$  hustota  $X$ , pak máme

$$\phi(t) = \int_{-\infty}^{\infty} f(x) e^{itx} dx.$$

Až na znaménko je to Fourierova transformace hustoty. Využití charakteristické funkce se tedy redukuje na počítání s Fourierovou transformací.

## 3.2 Základní vlastnosti Fourierovy transformace

V této podkapitole budeme uvažovat funkce které jsou současně spojité a integrovatelné v absolutní hodnotě. Prostor takových funkcí budeme označovat  $L^1 \cap C$ .

**Definice 3.2.1.** *Fourierova transformace* funkce  $f$  je funkce

$$\widehat{f}(\xi) = \int_{-\infty}^{\infty} f(x) e^{-i\xi x} dx.$$

Tedy je-li  $f$  hustota náhodné veličiny  $X$ , pak vztah mezi charakteristickou funkcí  $X$  a Fourierovou transformací funkce  $f$  je

$$\phi(-t) = \widehat{f}(t).$$

Z linearity integrálu plyne, že Fourierova transformace je lineární operace. Pro každé dvě funkce  $f, g$  a konstanty  $a, b$  platí

$$\widehat{af + bg} = a\widehat{f} + b\widehat{g}.$$

**Lemma 3.2.2.** *(O změně měřítka)* Pro  $f \in L^1 \cap C$  a  $R > 0$  označme  $f_R(x) = f(Rx)$  (tedy  $f_R$  je původní funkce vyjádřená v jiné volbě jednotek). Pak

$$\widehat{f_R}(\xi) = \frac{1}{R} \widehat{f}\left(\frac{\xi}{R}\right).$$

**Důkaz:** Z definice

$$\widehat{f_R}(\xi) = \int_{-\infty}^{\infty} f_R(x) e^{-i\xi x} dx = \int_{-\infty}^{\infty} f(Rx) e^{-i\xi x} dx.$$

Substitucí  $y = Rx$  dostaneme

$$\int_{-\infty}^{\infty} f(y) e^{-i\frac{\xi}{R}y} \frac{1}{R} dy = \frac{1}{R} \int_{-\infty}^{\infty} f(y) e^{-i\frac{\xi}{R}y} dy = \frac{1}{R} \widehat{f}\left(\frac{\xi}{R}\right).$$

□

**Lemma 3.2.3.** *(O Fourierově transformaci derivace)*. Nechť  $f \in L^1 \cap C$ ,  $f' \in L^1 \cap C$  a  $\lim_{x \rightarrow \pm\infty} f(x) = 0$ . Pak

$$\widehat{f'}(\xi) = i\xi \widehat{f}(\xi).$$

Derivování se tedy Fourierovou transformací převádí na obyčejné násobení faktorem  $i\xi$ .

**Důkaz:** Integrováním per partes dostaneme

$$\widehat{(f')}(\xi) = \int_{-\infty}^{\infty} f'(x)e^{-i\xi x} dx = [e^{-i\xi x} f(x)]_{-\infty}^{\infty} - (-i\xi) \int_{-\infty}^{\infty} f(x)e^{-i\xi x} dx = i\xi \hat{f}(\xi).$$

□

Obecně, je-li  $f, f', \dots, f^{(k)} \in L^1 \cap C$  a  $\lim_{x \rightarrow \pm\infty} f^j(x) = 0$  pro  $j = 0, 1, \dots, k-1$ , pak  $k$ -násobným integrováním per partes dostaneme

$$\widehat{(f^{(k)})}(\xi) = (i\xi)^k \hat{f}(\xi).$$

**Lemma 3.2.4.** (*O derivaci Fourierovy transformace*) Nechť  $f \in L^1 \cap C$  a  $g(x) = xf(x) \in L^1 \cap C$ . Pak  $\hat{f}(\xi)$  je diferencovatelná a platí

$$\frac{d\hat{f}}{d\xi} = -i\hat{g}(\xi).$$

**Důkaz:** Derivováním vztahu

$$\hat{f}(\xi) = \int_{-\infty}^{\infty} f(x)e^{-i\xi x} dx$$

podle parametru  $\xi$  dostaneme

$$\frac{d\hat{f}}{d\xi}(\xi) = \int_{-\infty}^{\infty} f(x)(-ix)e^{-i\xi x} dx = -i \int_{-\infty}^{\infty} [f(x)x] e^{-i\xi x} dx = -i\hat{g}(\xi).$$

Pro  $f, g \in L^1$  je jejich **konvoluce** definována vztahem

$$f * g(x) = \int_{-\infty}^{\infty} f(x-y)g(y)dy.$$

Substitucí  $y' = x - y$  dostaneme alternativní vyjádření

$$f * g(x) = \int_{-\infty}^{\infty} f(y)g(x-y)dy = g * f(x).$$

Konvoluce je tedy komutativní operace.



**Lemma 3.2.5.** (*O Fourierově transformaci konvoluce*) Necht  $f, g \in L^1(\mathbb{R})$ . Pak

$$\widehat{f * g}(\xi) = \hat{f}(\xi)\hat{g}(\xi).$$

**Důkaz:** S použitím Fubiniho věty dostaneme

$$\begin{aligned} \widehat{f * g}(\xi) &= \int_{-\infty}^{\infty} \left( \int_{-\infty}^{\infty} f(x-y)g(y)dy \right) e^{-i\xi x} dx = \\ &= \int \int_{\mathbb{R}^2} e^{-i\xi x} f(x-y)g(y)dydx = \int \int_{\mathbb{R}^2} e^{-i\xi(x-y)} f(x-y)e^{-i\xi y} g(y)dydx = \\ &= \int_{-\infty}^{\infty} \left( \int_{-\infty}^{\infty} e^{-i\xi(x-y)} f(x-y)dx \right) e^{-i\xi y} g(y)dy = \hat{f}(\xi) \int_{-\infty}^{\infty} e^{-i\xi y} g(y)dy = \hat{f}(\xi)\hat{g}(\xi). \end{aligned}$$

**Lemma 3.2.6.** (*O transformaci posunutí a o posunutí transformace*) Necht  $f \in L^1 \cap C$ . Pro  $a > 0$  označme  $f_a(x) = f(x-a)$ . Pak

$$\hat{f}_a(\xi) = \hat{f}(\xi)e^{-ia\xi}.$$

Naopak,

$$\widehat{fe^{iax}}(\xi) = \hat{f}(\xi - a).$$

**Důkaz:** Na jedné straně substitucí  $y = x - a$  dostaneme

$$\begin{aligned} \hat{f}_a(\xi) &= \int_{-\infty}^{\infty} f(x-a)e^{-i\xi x} dx = \int_{-\infty}^{\infty} f(y)e^{-i\xi(y+a)} dy = e^{-ia\xi} \int_{-\infty}^{\infty} f(y)e^{-i\xi y} dy = \\ &= e^{-ia\xi} \hat{f}(\xi). \end{aligned}$$

Naopak,

$$\widehat{fe^{iax}}(\xi) = \int_{-\infty}^{\infty} f(x)e^{iax}e^{-i\xi x} dx = \int_{-\infty}^{\infty} f(x)e^{-i(\xi-a)x} dx = \hat{f}(\xi - a).$$

□

**Důsledek 3.2.7.** Necht Fourierova transformace funkce  $f(x)$  je  $F(\xi)$ . Pak Fourierova transformace funkce  $f(x) \sin \omega x$  je rovna

$$\frac{i}{2}[F(\xi + \omega) - F(\xi - \omega)].$$

Tento vztah s obvykle nazývá modulační identita ( $f$  je původní signál,  $\omega$  je nosná frekvence, součin  $f(x)e^{i\omega x}$  je namodulovaný signál)

**Důkaz:** Víme, že

$$\sin \omega x = \frac{e^{i\omega x} - e^{-i\omega x}}{2i}$$

a

$$\widehat{f(x)e^{i\omega x}}(\xi) = \hat{F}(\xi - \omega).$$

Tedy

$$\widehat{f(x) \sin \omega x}(\xi) = \frac{1}{2i}[F(\xi - \omega) - F(\xi + \omega)] = \frac{i}{2}[F(\xi + \omega) - F(\xi - \omega)].$$

□

**Lemma 3.2.8.** (*Fourierova transformace Gaussovy funkce*) *Je-li*

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}},$$

*pak*

$$\hat{f}(\xi) = e^{-\frac{\xi^2}{2}}.$$

**Důkaz:** Označme opět  $F(\xi) = \hat{f}(\xi)$ . Máme

$$f'(x) = -\frac{1}{\sqrt{2\pi}} x e^{-\frac{x^2}{2}} = -x f(x).$$

Na jedné straně je

$$\widehat{(-x f(x))}(\xi) = \hat{f}'(\xi) = i\xi F(\xi),$$

podle lemmatu o transformaci derivace, na druhé straně, z lemmatu o derivaci transformace, je

$$\widehat{(-ix f)}(\xi) = F'(\xi).$$

Celkem  $F$  splňuje rovnici

$$F'(\xi) = -\xi F(\xi).$$

Separací proměnných dostaneme řešení

$$F(\xi) = C e^{-\frac{\xi^2}{2}}.$$

Konstanta  $C$  je rovna hodnotě  $\hat{f}$  v bodě nula, tedy Laplaceovu integrálu

$$\hat{f}(0) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{x^2}{2}} dx = 1.$$

□

**Příklad 3.2.9.** Označme jako  $H(x)$  Heavisideovu funkci, tedy  $H(x) = 1$  pro  $x \geq 0$  a  $H(x) = 0$  pro  $x < 0$ . Je-li

$$f(x) = e^{-ax}H(x)$$

pro nějaké  $a > 0$ , pak

$$\hat{f}(\xi) = \frac{1}{a + i\xi}.$$

Opravdu,

$$\begin{aligned} \hat{f}(\xi) &= \int_0^{\infty} e^{-ax} e^{-i\xi x} dx = \int_0^{\infty} e^{-(a+i\xi)x} dx = \\ &= -\frac{1}{a+i\xi} [e^{-(a+i\xi)x}]_0^{\infty} = \frac{1}{a+i\xi}. \end{aligned}$$

Dále uvažujme funkci

$$f(x) = e^{-a|x|}.$$

Pomocí Heavisideovy funkce ji můžeme napsat jako

$$f(x) = H(x)e^{-ax} + H(-x)e^{ax}.$$

Její Fourierova transformace je rovna

$$\hat{f}(\xi) = \frac{1}{a+i\xi} + \frac{1}{a-i\xi} = \frac{2a}{a^2+x^2}.$$

**Věta 3.2.10.** (Základní identita pro Fourierovu transformaci) Nechť  $f, g \in L^1 \cap C$ . Pak platí

$$\int_{-\infty}^{\infty} f\hat{g} = \int_{-\infty}^{\infty} \hat{f}g.$$

**Důkaz:** Z Fubiniho věty dostaneme

$$\int_{-\infty}^{\infty} f(x)\hat{g}(x)dx = \int_{-\infty}^{\infty} f(x) \int_{-\infty}^{\infty} g(y)e^{-ixy} dy dx =$$

$$\int \int_{\mathbb{R}^2} f(x)g(y)e^{-ixy} dy dx = \int_{-\infty}^{\infty} g(y) \int_{-\infty}^{\infty} f(x)e^{-ixy} dx dy = \int_{-\infty}^{\infty} g(y)\hat{f}(y) dy.$$

□

**Věta 3.2.11.** (*O inverzní transformaci*) Nechť  $f \in L^1 \cap C$ ,  $f$  je stejnoměrně spojitá a  $\hat{f} \in L^1 \cap C$ . Pak  $f(x)$  lze vypočítat z  $\hat{f}(\xi)$  vztahem

$$f(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \hat{f}(\xi)e^{i\xi x} d\xi.$$

□

Pro aplikace v teorii pravděpodobnosti je klíčový následující důsledek.

**Důsledek 3.2.12.** Charakteristická funkce jednoznačně určuje hustotu náhodné veličiny.

### 3.3 Základy $L^2$ -teorie

V této části budeme uvažovat funkce na obecném intervalu  $\langle a, b \rangle$  s hodnotami v  $\mathbb{C}$  a prostor

$$L^2(\langle a, b \rangle)$$

obsahující funkce, pro které

$$\int_a^b |f(x)|^2 dx < \infty.$$

$L^2(\langle a, b \rangle)$  je Hilbertův prostor (nekonečněrozměrná analogie Euklidovského prostoru) se skalárním součinem

$$(f, g) = \int_a^b f(x)\overline{g(x)} dx.$$

Skalární součin indukuje, stejně jako v Euklidovském prostoru, na  $L^2(\langle a, b \rangle)$  normu

$$\|f\| = \left( \int_a^b |f(x)|^2 dx \right)^{\frac{1}{2}}$$

a také metriku. Vzdálenost dvou funkcí je číslo

$$\rho(f, g) = \|f - g\| = \left( \int_a^b |f(x) - g(x)|^2 dx \right)^{\frac{1}{2}}.$$

**Definice 3.3.1.** Systém funkcí  $\{\phi_k\}_{k=0}^{\infty}$  se nazývá ortogonální systém, jestliže

$$(\phi_n, \phi_m) = 0$$

pro každé  $n \neq m$ . Nazývá se ortonormální systém, jestliže navíc platí

$$(\phi_n, \phi_n) = 1$$

pro všechna  $n \in \mathbb{N}$ .

**Definice 3.3.2.** Nechť  $\{\phi_k\}_{k=0}^{\infty}$  je ortonormální systém. Čísla

$$c_k = \int_a^b f(x) \bar{\phi}_k(x) dx$$

se nazývají *Fourierovy koeficienty funkce  $f$  vzhledem k systému  $\{\phi_k\}_{k=0}^{\infty}$* . *Formální funkční řada*

$$\sum_{k=0}^{\infty} c_k \phi_k$$

*se nazývá Fourierova řada.*

Pomocí Fourierových koeficientů definujeme funkce

$$f_N = \sum_{k=0}^N c_k \phi_k.$$

Zajímá nás, za jakých podmínek konverguje  $f_N$  pro  $N \rightarrow \infty$  k funkci  $f$ . Konvergencí v tomto případě rozumíme konvergenci v normě prostoru  $L^2$ . Následující lemma ukazuje, že  $f_N$  je nejlepší aproximací  $f$  mezi všemi lineárními kombinacemi funkcí  $\phi_1, \phi_2, \dots, \phi_N$ .

**Lemma 3.3.3.** *Nechť  $\{\phi_k\}_{k=0}^{\infty}$  je ortonormální systém a  $f \in L^2$ . Pak pro libovolná komplexní čísla  $d_1, \dots, d_N$  platí*

$$\|f - \sum_{j=0}^N d_j \phi_j\| \geq \|f - f_N\|.$$

*Rovnost přitom nastane pouze tehdy, je-li  $d_j = c_j$  pro všechna  $j = 0, \dots, N$ .*

**Důkaz:** Máme

$$\|f - \sum_{j=0}^N d_j \phi_j\|^2 = (f - \sum_{j=0}^N d_j \phi_j, f - \sum_{j=0}^N d_j \phi_j) =$$

$$\begin{aligned}
&= (f, f) - (f, \sum_{j=0}^N d_j \phi_j) - (\sum_{j=0}^N d_j \phi_j, f) + (\sum_{j=0}^N d_j \phi_j, \sum_{j=0}^N d_j \phi_j) = \\
&= \|f\|^2 - \sum_{j=0}^N c_j \bar{d}_j - \sum_{j=0}^N \bar{c}_j d_j + \sum_{j=0}^N d_j \bar{d}_j = \\
&= \|f\|^2 + \sum_{j=0}^N |c_j - d_j|^2 - \sum_{j=0}^N |c_j|^2.
\end{aligned}$$

První a poslední člen nezávisí na koeficientech  $d_j$ , prostřední člen je nezáporný a minimalizuje se právě tehdy, když  $d_j = c_j$  pro  $j = 0, \dots, N$ .

**Lemma 3.3.4.** *Fourierova řada*

$$\sum_{k=0}^{\infty} c_k \phi_k$$

konverguje v normě  $L^2$  k funkci  $f$  právě tehdy, když platí Parsevalova rovnost

$$\sum_{j=0}^{\infty} |c_j|^2 = \|f\|^2.$$

Ve dvoudimenzionálním prostoru se Parsevalova rovnost redukuje na Pythagorovu větu.

Pro dvě funkce platí Parsevalova rovnost ve tvaru

$$(f, g) = \int_a^b f(x) \overline{g(x)} = \sum_{k=0}^{\infty} c_k \bar{d}_k,$$

kde  $c_k$  jsou Fourierovy koeficienty funkce  $f$ ,  $d_k$  jsou Fourierovy koeficienty funkce  $g$  a obě Fourierovy řady funkcí  $f$  a  $g$  konvergují.

**Definice 3.3.5.** Ortonormální systém je **úplný** jestliže platí: Pokud pro nějakou funkci  $g \in L^2([a, b])$  platí  $(g, \phi_k) = 0$  pro všechna  $k = 0, 1, \dots$ , pak  $g = 0$ . Tedy neexistuje nenulová funkce kolmá na všechny prvky systému.

**Lemma 3.3.6.** *Fourierova řada konverguje pro každou funkci  $f \in L^2([a, b])$  právě tehdy, když systém  $\{\phi_k\}_{k=0}^{\infty}$  je úplný.*

### 3.4 Borel-Cantelliho lemma

Pro počítání s nekonečnými posloupnostmi jevů a náhodných veličin je důležitým nástrojem Borel-Cantelliho lemma.

**Lemma 3.4.1. (Borel-Cantelli)** *Nechť  $(\Omega, \mathcal{A}, P)$  je pravděpodobnostní prostor. Nechť  $A_n \subseteq \Omega$ ,  $n = 1, 2, \dots$  je posloupnost jevů. Označme jako  $A$  jev, že nastává nekonečně mnoho  $A_n$ , tedy*

$$A = \bigcap_{n=1}^{\infty} \bigcup_{m=n}^{\infty} A_m.$$

Pak platí:

1. Jestliže

$$\sum_{n=1}^{\infty} P(A_n) < \infty$$

(tj. řada konverguje), pak  $P(A) = 0$ .

2. Jestliže

$$\sum_{n=1}^{\infty} P(A_n) = \infty$$

(tj. řada diverguje) a  $A_n$  jsou nezávislé, potom  $P(A) = 1$ .

**Důkaz:** Máme

$$\omega \in A \iff \omega \in \bigcup_{m=n}^{\infty} A_m \text{ pro všechna } n = 1, 2, \dots$$

Platí

$$A \subseteq \bigcup_{m=n}^{\infty} A_m$$

pro všechna  $n$ . Tedy

$$0 \leq P(A) \leq P\left(\bigcup_{m=n}^{\infty} A_m\right) \leq \sum_{m=n}^{\infty} P(A_m).$$

Ale

$$\sum_{m=n}^{\infty} P(A_m)$$

je limita částečných součtů a z definice konvergence tedy platí

$$\sum_{m=n}^{\infty} P(A_m) \rightarrow 0$$

pro  $n \rightarrow \infty$ , čímž je první tvrzení dokázáno.

Pro důkaz druhé části, musíme dokázat, že  $P(A^C) = 0$ , kde

$$A^C = \bigcup_{n=0}^{\infty} \bigcap_{m=n}^{\infty} A_m^C.$$

Máme tedy s využitím nezávislosti a odhadu  $1 - x \leq e^{-x}$  pro  $x \geq 0$ ,

$$\begin{aligned} P\left(\bigcap_{m=n}^{\infty} A_m^C\right) &= \lim_{r \rightarrow \infty} P\left(\bigcap_{m=n}^r A_m^C\right) = \prod_{m=n}^{\infty} (1 - P(A_m)) \leq \prod_{m=n}^{\infty} \exp(-P(A_m)) = \\ &= \exp\left(-\sum_{m=n}^{\infty} P(A_m)\right) = 0 \end{aligned}$$

kdykoliv  $\sum_{m=n}^{\infty} P(A_m) = \infty$ . Tedy

$$P(A^C) = \lim_{n \rightarrow \infty} P\left(\bigcap_{m=n}^{\infty} A_m^C\right) = 0,$$

neboli  $P(A) = 1$ , což jsme chtěli dokázat.



# Kapitola 4

## Wienerův proces

### 4.1 Definice Wienerova procesu

**Definice 4.1.1.** Reálný stochastický proces  $W(t)$  na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$  se nazývá **Wienerův proces**, jestliže platí:

1.  $W(0) = 0$ .
2. (*spojitost trajektorií*) S pravděpodobností 1 je funkce  $t \rightarrow W(t)$  spojitá v  $t$ .
3. (*nezávislost a normalita přírůstků*) Přírůstky  $W(t) - W(s)$  mají rozdělení  $N(0, t - s)$ . Pro libovolné  $0 < t_1 < t_2 < \dots < t_n$  jsou přírůstky  $W(t_1), W(t_2) - W(t_1), \dots, W(t_n) - W(t_{n-1})$  navzájem nezávislé.

V následujícím textu budeme považovat pojmy Wienerův proces a Brownův pohyb za synonyma, stejně tak budeme zaměňovat značení  $W(t)$  a  $W_t$ .

Nejdříve se budeme zabývat otázkou, zda takový proces vůbec existuje, a ukážeme si jednu z možných konstrukcí Wienerova procesu.

### 4.2 Haarovy a Schauderovy funkce

Wienerův proces zkonstruujeme jako náhodný součet tzv. Schauderových funkcí, které vyniknou jako integrál z Haarových funkcí.

**Definice 4.2.1.** Pro  $t \in [0, 1]$  definujeme **Haarovy funkce**  $\{h_k(t)\}_{k=0}^{\infty}$  následujícím způsobem. Pro  $k = 0$  položíme

$$h_0(t) = 1$$

pro  $t \in [0, 1]$ . Dále

$$h_1(t) = \begin{cases} 1 & \text{pro } t \in [0, \frac{1}{2}] \\ -1 & \text{pro } t \in (\frac{1}{2}, 1] \end{cases}$$

Pro  $n > 1$  nejdříve vyjádříme  $n$  ve tvaru

$$n = 2^j + k$$

kde  $j \geq 0$ ,  $0 \leq k < 2^j$  (tzv. *dyadické vyjádření čísla  $n$* ), a definujeme

$$h_n(t) = 2^{\frac{j}{2}} h_1(2^j t - k).$$

$2^{\frac{j}{2}}$  je normalizační konstanta, faktor  $2^j$  představuje změnu měřítka a  $k$  posun (určuje polohu nosiče).

Připomeňme v této souvislosti pojem *nosič funkce*,

$$\text{supp } f = \overline{\{x \in \mathbb{R}; f(x) \neq 0\}}.$$

Například,

$$\text{supp } (h_4) = \left[0, \frac{1}{4}\right].$$

Pro  $n = 73$  máme dyadické vyjádření

$$73 = 64 + 9 = 2^6 + 9,$$

tedy úroveň je  $j = 6$  a poloha je  $k = 9$ .

Podobně pro  $n = 51$  je  $51 = 32 + 19 = 2^5 + 19$ , tedy úroveň je  $j = 5$  a poloha je  $k = 19$ .

**Věta 4.2.2.** *Funkce  $\{h_k\}_{k=0}^{\infty}$  tvoří úplný, ortonormální systém v prostoru  $L^2([0, 1])$ .*

**Důkaz:** Nejdříve dokážeme ortogonálnost, tedy

$$\langle h_n, h_m \rangle = 0$$

pro  $m \neq n$ . Nechť  $n = 2^j + k$  a  $m = 2^{j'} + k'$ . Pro  $j = j'$  je

$$\text{supp } (h_n) \cap \text{supp } (h_m)$$

buď prázdná nebo jednobodová množina. Tedy

$$\int_0^1 h_n(x) h_m(x) dx = \int_0^1 0 dx = 0.$$

Pro  $j \neq j'$  musíme uvažovat dva případy, disjunktní a nedisjunktní nosiče  $h_n$  a  $h_m$ . V prvním případě je opět součin identická nula. V druhém případě předpokládejme bez újmy na obecnosti že  $m > n$ . Nosič  $h_m$  musí ležet v intervalu, kde  $h_n$  je konstantní, tedy

$$\int_0^1 h_n h_m = \pm 2^{\frac{j}{2}} \int_0^1 h_m = 0.$$

Dále ukážeme, že  $\langle h_n, h_n \rangle = 1$ , tedy ortonormalitu systému. Pro  $n = 1$  máme

$$\|h_1\|^2 = \int_0^1 h_1^2(x) dx = \int_0^1 1 dx = 1.$$

Pro  $n > 1$  dostaneme

$$\|h_n\|^2 = \int_0^1 h_n^2(x) dx = \left(2^{\frac{j}{2}}\right)^2 \int_0^1 h_1^2(2^j t - k) dt.$$

Po substituci  $u = 2^j t - k$  dostáváme

$$\left(2^{\frac{j}{2}}\right)^2 \int_0^1 h_1^2(2^j t - k) dt = \int_{-k}^{2^j - k} h_1^2(u) du = \int_0^1 h_1^2(u) du = 1.$$

Úplnost systému plyne z jeho uzavřenosti. Pro každé  $f \in L^2([0, 1])$  existuje posloupnost konečných lineárních kombinací funkcí z  $\{h_k\}_{k=0}^{\infty}$ , která konverguje k  $f$ . Opravdu, z Haarových funkcí jako lineární kombinace dostaneme funkce po částech konstantní na dyadických intervalech, pomocí kterých můžeme libovolně dobře aproximovat funkce spojitě. Na druhé straně, spojitě funkce tvoří hustou podmnožinu v  $L^2$ . Odtud plyne tvrzení.

Integrováním Haarových funkcí dostaneme Schauderovy funkce.

**Definice 4.2.3.** Pro  $n = 1, 2, \dots$  definujeme  $n$ -tou **Schauderovu funkci** vztahem

$$s_n(t) = \int_0^t h_n(s) ds$$

pro  $t \in [0, 1]$ .

Grafem  $n$ -té Schauderovy funkce je rovnoramenný trojúhelník, jehož výška je  $\frac{1}{2^{j+1}} 2^{\frac{j}{2}} = 2^{\frac{j}{2}-j-1} = 2^{-\frac{j}{2}-1}$ .

### 4.3 Ciesielskiho konstrukce

Následující dvě technická lemmata jsou potřeba k důkazu spojitosti trajektorií v Ciesielskiho konstrukci.

**Lemma 4.3.1.** *Nechť  $\{a_k\}_{k=1}^{\infty}$  je posloupnost reálných čísel,  $0 \leq \delta < \frac{1}{2}$  a necht' platí  $|a_k| = O(k^\delta)$ , tedy existuje konstanta  $c > 0$  tak, že  $|a_k| \leq ck^\delta$ . Pak řada  $\sum_{k=1}^{\infty} a_k s_k(t)$  konverguje stejnoměrně pro  $t \in [0, 1]$ .*

**Důkaz:** Zvolme  $\varepsilon > 0$ . Pro  $2^n \leq k < 2^{n+1}$  mají funkce  $s_k(t)$  disjunktní nosiče. Položme

$$b_n = \max_{2^n \leq k < 2^{n+1}} |a_k| \leq c(2^{n+1})^\delta.$$

Pak pro  $0 \leq t \leq 1$  platí:

$$\begin{aligned} \sum_{k=2^m}^{\infty} |a_k| |s_k(t)| &\leq \sum_{n=m}^{\infty} b_n 2^n \leq \max_{k < 2^{n+1}} |s_k(t)| \leq c \sum_{n=m}^{\infty} (2^{n+1})^\delta 2^{-\frac{n}{2}-1} = \\ &= c 2^{(\delta-1)} \sum_{n=m}^{\infty} 2^{n(\delta-\frac{1}{2})} < \varepsilon \end{aligned}$$

pro dostatečně velké  $m$ , neboť  $\delta - \frac{1}{2} < 0$  a tedy řada

$$\sum_{n=1}^{\infty} 2^{n(\delta-\frac{1}{2})}$$

konverguje.

**Lemma 4.3.2.** *Nechť  $\{A_k\}_{k=1}^{\infty}$  jsou nezávislé náhodné veličiny na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$  s rozdělením  $N(0, 1)$ . Pak pro skoro všechna  $\omega \in \Omega$  platí, že  $|A_k| = O(\sqrt{\log k})$  pro  $k \rightarrow \infty$  (tedy existuje  $c \in \mathbb{R}$  tak, že  $|A_k| \leq c\sqrt{\log k}$ ).*

**Důkaz:** Pro  $x > 0$  a  $k = 1, 2, \dots$  máme:

$$\begin{aligned} P(|A_k| > x) &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{-x} e^{-\frac{s^2}{2}} ds + \frac{1}{\sqrt{2\pi}} \int_x^{\infty} e^{-\frac{s^2}{2}} ds = \\ &= \frac{2}{\sqrt{2\pi}} \int_x^{\infty} e^{-\frac{s^2}{2}} ds \leq \frac{2}{\sqrt{2\pi}} e^{-\frac{x^2}{4}} \int_x^{\infty} e^{-\frac{s^2}{4}} ds \leq c e^{-\frac{x^2}{4}} \end{aligned}$$

pro nějakou konstantu  $c$ , protože  $e^{-\frac{s^2}{4}}$  je klesající na  $[x, \infty)$ . Můžeme vzít např.  $c = \frac{2}{\sqrt{2\pi}} \int_{-\infty}^{\infty} e^{-\frac{s^2}{4}} ds$ .

Položme  $x = 4\sqrt{\log k}$ . Potom

$$P\left(|A_k| > 4\sqrt{\log k}\right) \leq ce^{-4\log k} = c\frac{1}{k^4}.$$

Protože řada  $\sum_{k=1}^{\infty} \frac{1}{k^4}$  konverguje, z Borel-Cantelliho lemmatu máme

$$P\left(|A_k| > 4\sqrt{\log k} \text{ pro nekonečně mnoho } k\right) = 0.$$

Tedy pro skoro všechna  $\omega$  je  $|A_k| \leq c\sqrt{\log k}$  pro nějakou konstantu  $c$ .

**Věta 4.3.3.** *Nechť  $W(t)$  je Wienerův proces. Pak*

$$\text{Cov}(W(t), W(s)) = E(W(t)W(s)) = \min(t, s).$$

**Důkaz:** Nechť  $s \geq t \geq 0$ . Máme

$$\begin{aligned} E(W(t)[W(t) + (W(s) - W(t))]) &= E(W^2(t)) + E(W(t)[W(s) - W(t)]) = \\ &= t = \min(t, s), \end{aligned}$$

protože  $E(W^2(t)) = t$  z definice a

$$E(W(t)[W(s) - W(t)]) = 0$$

z nezávislosti přírůstků.

**Věta 4.3.4.** *Pro libovolná  $0 \leq s, t \leq 1$  platí*

$$\sum_{k=1}^{\infty} s_k(s) s_k(t) = \min(s, t).$$

**Důkaz:** Pro libovolné pevné  $s \in [0, 1]$  definujeme funkce

$$g_s(\tau) = \begin{cases} 1 & \text{pro } \tau \leq s \\ 0 & \text{pro } s < \tau \leq 1. \end{cases}$$

Podle Parsevalovy rovnosti (protože Haarovy funkce tvoří ortonormální úplný systém v  $L^2([0, 1])$ ) máme pro  $s \leq t$ :

$$s = \int_0^1 g_t(x) g_s(x) dx = \sum_0^{\infty} a_k b_k,$$

kde pro koeficienty  $a_k, b_k$  platí

$$a_k = \langle g_t, h_k \rangle = \int_0^1 g_t(x) h_k(x) dx = \int_0^t h_k(x) dx = s_k(t)$$

a

$$b_k = \langle g_s, h_k \rangle = \int_0^1 g_s(x) h_k(x) dx = \int_0^s h_k(x) dx = s_k(s).$$

Celkem tedy  $\min(s, t) = s = \sum_0^\infty s_k(t) s_k(s)$ .

**Věta 4.3.5. (Ciesielskiho konstrukce Wienerova procesu):** *Nechť  $\{A_k\}_{k=1}^\infty$  je posloupnost nezávislých náhodných veličin s rozdělením  $N(0, 1)$ , definovaných na daném pravděpodobnostním prostoru. Pak součet*

$$W(t, \omega) = \sum_{k=1}^{\infty} A_k(\omega) s_k(t)$$

pro  $0 \leq t \leq 1$  konverguje stejnoměrně v  $t$  pro skoro všechna  $\omega$ , a  $W(t, \omega)$  je Wienerův proces.

**Důkaz:** Stejnomořná konvergence plyne z předchozích lemmat. Ze stejno-  
měrné konvergence řady spojitých funkcí plyne spojitost trajektorie procesu  
 $t \rightarrow W(t, \omega)$ .

Musíme ověřit, že  $W(t, \omega)$  je Wienerův proces. Zřejmě  $W(0) = 0$ , protože  
 $s_k(0) = 0$  pro všechna  $k$ .

Dále pomocí charakteristické funkce dokážeme, že  $W(t) - W(s)$  pro  $s < t$   
má rozdělení  $N(0, t - s)$ . Nechť  $s < t$ . Z definice  $W$ , nezávislosti  $A_k \sim$   
 $N(0, 1)$  a znalosti charakteristické funkce rozdělení  $N(0, 1)$ ,

$$E(e^{itA_k}) = e^{-\frac{t^2}{2}},$$

máme

$$\begin{aligned} E[e^{i\lambda(W(t)-W(s))}] &= E\left[e^{i\lambda\sum_{k=1}^{\infty} A_k(s_k(t)-s_k(s))}\right] = E\left(\prod_{k=1}^{\infty} [e^{i\lambda A_k(s_k(t)-s_k(s))}]\right) = \\ &= \prod_{k=1}^{\infty} E[e^{i\lambda A_k(s_k(t)-s_k(s))}] = \prod_{k=1}^{\infty} e^{-\frac{\lambda^2}{2}[s_k(t)-s_k(s)]^2} = e^{-\frac{\lambda^2}{2}\sum_{k=1}^{\infty}[s_k(t)-s_k(s)]^2} = \\ &= e^{-\frac{\lambda^2}{2}\sum_{k=1}^{\infty} s_k^2(t) - 2s_k(t)s_k(s) + s_k^2(s)}. \end{aligned}$$

Trojnásobným použitím pomocného tvrzení

$$\sum_{k=1}^{\infty} s_k(s) s_k(t) = \min(s, t)$$

dostaneme

$$e^{-\frac{\lambda^2}{2} \sum_{k=1}^{\infty} s_k^2(t) - 2s_k(t)s_k(s) + s_k^2(s)} = e^{-\frac{\lambda^2}{2}[t-2s+s]} = e^{-\frac{\lambda^2}{2}[t-s]}.$$

To je ale charakteristická funkce rozdělení  $N(0, t-s)$ . Z jednoznačnosti charakteristické funkce plyne

$$W(t) - W(s) \sim N(0, t-s).$$

Zbývá dokázat nezávislost přírůstků. Protože přírůstky mají normální rozdělení, stačí dokázat nekorelovanost,

$$E([W(t_{i+1}) - W(t_i)][W(t_{j+1}) - W(t_j)]) = 0$$

pro  $i \neq j$ .

Nejdříve vypočteme z definice  $W$  pro  $s < t$

$$E[W(t)W(s)] =$$

$$\begin{aligned} & E \left[ \left( \sum_{k=1}^{\infty} A_k(\omega) s_k(t) \right) \left( \sum_{k=1}^{\infty} A_k(\omega) s_k(s) \right) \right] = \\ & = E \left[ \left( \sum_{k=1}^{\infty} \sum_{l=1}^{\infty} A_k(\omega) A_l(\omega) s_k(t) s_l(s) \right) \right] = \\ & = E \left( \sum_{k=1}^{\infty} [A_k^2(\omega)] s_k(t) s_k(s) \right), \end{aligned}$$

protože z nezávislosti

$$E(A_k(\omega) A_l(\omega)) = 0$$

pro  $k \neq l$ . Tedy

$$\begin{aligned} & E \left( \sum_{k=1}^{\infty} [A_k^2(\omega)] s_k(t) s_k(s) \right) = \\ & = \sum_{k=1}^{\infty} E[A_k^2(\omega)] s_k(t) s_k(s) = \sum_{k=1}^{\infty} s_k(t) s_k(s) = \min(t, s) = s, \end{aligned}$$

neboť  $A_k \sim N(0, 1)$ . Bez újmy na obecnosti můžeme předpokládat  $t_i < t_j$ . Z předchozího výpočtu máme

$$E([W(t_{i+1}) - W(t_i)][W(t_{j+1}) - W(t_j)]) =$$

$$= E[W(t_{i+1})W(t_{j+1}) - W(t_i)W(t_{j+1}) - W(t_{i+1})W(t_j) + W(t_i)W(t_j)] =$$

$$= t_{i+1} - t_i - t_{i+1} + t_i = 0.$$

Přírůstky jsou tedy nekorelované a tím pádem nezávislé.

Analogicky se dokáže vzájemná nezávislost více než dvou přírůstků, s využitím vlastností vícerozměrného normálního rozdělení.



# Kapitola 5

## Lineární a kvadratická variace

### 5.1 Lineární variace

**Variace** je míra proměnlivosti (variability) funkce na daném intervalu. Nechť  $f : [a, b] \rightarrow \mathbb{R}$  je spojitá funkce a necht'  $D = \{a = t_1 < t_2 < \dots < t_n = b\}$  je dělení intervalu  $[a, b]$ .

Lineární variace vzhledem k dělení  $D$  je definována jako

$$LV(f, D) = \sum_{j=1}^{n-1} |f(t_{j+1}) - f(t_j)|.$$

**Definice 5.1.1.** *Lineární variace funkce  $f$*  je definována jako limita

$$LV(f) = \lim_{\|D\| \rightarrow 0} LV(f, D),$$

kde  $\|D\|$  je norma dělení, tj.

$$\|D\| = \max_j |t_{j+1} - t_j|.$$

**Příklad 5.1.2.** Funkce  $f(x) = x^2$  na intervalu  $[0, 1]$  má lineární variaci

$$LV(f) = f(1) - f(0) = 1.$$

Opravdu, máme  $f(t_{j+1}) - f(t_j) > 0$  pro všechna  $j$ , neboť  $f$  je rostoucí. Lineární variace je tedy

$$LV(f, D) = \sum_{j=1}^{n-1} (f(t_{j+1}) - f(t_j)) =$$

$$= f(t_n) - f(t_1) = f(b) - f(a) = f(1) - f(0).$$

Obecně, je-li  $f$  monotonní na  $[a, b]$ , pak

$$LV(f) = |f(b) - f(a)|.$$

**Příklad 5.1.3.** Vypočtěte lineární variaci funkce  $\sin x$  na intervalu  $[0, 2\pi]$ . Funkce je po částech monotonní na jednotlivých podintervalech délky  $\frac{\pi}{2}$ , na každém z nich je variace rovna jedné. Sečtením jednotlivých variací dostáváme  $LV(f) = 4$ .

Nechť  $f : [0, T] \rightarrow \mathbb{R}$  je diferencovatelná funkce nabývající extrémů v bodech  $t_1$  a  $t_2$ . Pak

$$\begin{aligned} LV(f) &= |f(t_1) - f(0)| + |f(t_2) - f(t_1)| + |f(T) - f(t_2)| = \\ &= \int_0^{t_1} f'(x) dx - \int_{t_1}^{t_2} f'(x) dx + \int_{t_2}^T f'(x) dx = \int_0^T |f'(x)| dx. \end{aligned}$$

Obecně, je-li  $f$  diferencovatelná, pak podle věty o střední hodnotě pro každý podinterval  $[t_k, t_{k+1}]$  existuje bod  $t_k^*$  uvnitř tohoto intervalu tak, že

$$f(t_{k+1}) - f(t_k) = f'(t_k^*) (t_{k+1} - t_k),$$

tedy

$$\sum_{k=1}^{n-1} |f(t_{k+1}) - f(t_k)| = \sum_{k=1}^{n-1} |f'(t_k^*)| (t_{k+1} - t_k),$$

což je přibližný součet z definice Riemannova integrálu.

Limitním přechodem dostaneme

$$LV(f) = \lim_{\|D\| \rightarrow 0} \sum_{k=1}^{n-1} |f(t_{k+1}) - f(t_k)| = \int_0^T |f'(t)| dt.$$

Pro trajektorie Wienerova procesu není lineární variace užitečný pojem, protože je rovna nekonečnu pro skoro všechny trajektorie.

## 5.2 Kvadratická variace

**Definice 5.2.1.** Nechť  $D = \{t_1, \dots, t_n\}$  je dělení intervalu  $[0, T]$ , tedy  $0 = t_1 < t_2 < \dots < t_n = T$ . **Kvadratickou variaci** funkce  $f$  na intervalu  $[0, T]$  definujeme jako

$$KV(f) = \lim_{\|D\| \rightarrow 0} \sum_{k=1}^{n-1} (f(t_{k+1}) - f(t_k))^2,$$

pokud limita existuje.

**Lemma 5.2.2.** *Nechť  $f$  je diferencovatelná funkce na  $[0, T]$ , pak  $KV(f) = 0$ .*

**Důkaz:** Máme

$$\begin{aligned} KV(f) &= \lim_{\|D\| \rightarrow 0} \sum_{k=1}^{n-1} (f(t_{k+1}) - f(t_k))^2 = \\ &= \lim_{\|D\| \rightarrow 0} \sum_{k=1}^{n-1} |f'(t_k^*)|^2 (t_{k+1} - t_k)^2 \leq \lim_{\|D\| \rightarrow 0} \|D\| \sum_{k=1}^{n-1} |f'(t_k^*)|^2 (t_{k+1} - t_k) = \\ &= \lim_{\|D\| \rightarrow 0} \|D\| \int_0^T (f'(t))^2 dt = 0, \end{aligned}$$

neboť integrál  $\int_0^T (f'(t))^2 dt$  je konečný.

K výpočtu kvadratické variace trajektorie Wienerova procesu budeme potřebovat následující lemma.

**Lemma 5.2.3.** *Nechť  $W(t)$  je Wienerův proces. Pak*

$$\begin{aligned} E(W^2(t)) &= t \\ E(W^4(t)) &= 3t^2. \end{aligned}$$

**Důkaz:** Z definice víme, že  $W(t) - W(s) \sim N(0, t - s)$ . Speciálně pro  $s = 0$  je  $W(t) \sim N(0, t)$ , tedy  $E(W(t)) = 0$  a  $E(W^2(t)) = t$ . Dále,  $N(0, t)$  má hustotu  $\frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}}$ . Ze vztahu

$$E(g(X)) = \int_{-\infty}^{\infty} g(x) f(x) dx$$

máme

$$\begin{aligned}
E(W^4(t)) &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}} x^4 dx = \frac{1}{\sqrt{2\pi t}} \int_{-\infty}^{\infty} e^{-\frac{x^2}{2t}} x^4 dx \\
&= \frac{1}{\sqrt{2\pi t}} \left( \left[ e^{-\frac{x^2}{2t}} (-t) x^3 \right]_{-\infty}^{\infty} + \int_{-\infty}^{\infty} e^{-\frac{x^2}{2t}} t 3x^2 dx \right) \\
&= \frac{1}{\sqrt{2\pi t}} \left[ e^{-\frac{x^2}{2t}} (-t) x^3 \right]_{-\infty}^{\infty} + \frac{1}{\sqrt{2\pi t}} 3t \int_{-\infty}^{\infty} e^{-\frac{x^2}{2t}} x^2 dx \\
&= 0 + \frac{1}{\sqrt{2\pi t}} 3t \left( \left[ e^{-\frac{x^2}{2t}} (-t) x \right]_{-\infty}^{\infty} + \int_{-\infty}^{\infty} e^{-\frac{x^2}{2t}} (t) dx \right) = \frac{1}{\sqrt{2\pi t}} 3t^2 \int_{-\infty}^{\infty} e^{-\frac{x^2}{2t}} dx = \\
&= 3t^2 \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}} dx = 3t^2.
\end{aligned}$$

Využili jsme toho, že  $\left[ e^{-\frac{x^2}{2t}} (-t) x^3 \right]_{-\infty}^{\infty} = 0$ , jelikož exponenciála klesá rychleji než roste libovolná mocnina  $x$ .

**Věta 5.2.4.** *Nechť  $W(t)$  je Wienerův proces na intervalu  $[0, T]$  a nechť  $D = \{0 = t_1 < t_2 < \dots < t_n = T\}$  je dělení intervalu  $[0, T]$ . Pak*

$$\sum_{k=1}^{n-1} (W(t_{k+1}) - W(t_k))^2 \rightarrow T$$

pro  $\|D\| \rightarrow 0$  v  $L^2$ -normě.

**Důkaz:** Označme  $\Delta W_k = W(t_{k+1}) - W(t_k)$  a  $\Delta t_k = t_{k+1} - t_k$ . Chceme dokázat, že

$$E \left[ \left( \sum_{k=1}^{n-1} (\Delta W_k)^2 - T \right)^2 \right] \rightarrow 0$$

pro  $\|D\| \rightarrow 0$  (tj. konvergenci v  $L^2$ ). Máme

$$\begin{aligned}
E \left( \sum_{k=1}^{n-1} [(\Delta W_k)^2 - (t_{k+1} - t_k)] \right)^2 &= \sum_{k=1}^{n-1} E(\Delta W_k^4 - 2(t_{k+1} - t_k) \Delta W_k^2 + \\
&+ (t_{k+1} - t_k)^2) = \sum_{k=1}^{n-1} (3(t_{k+1} - t_k)^2 - 2(t_{k+1} - t_k)^2 + (t_{k+1} - t_k)^2) = \\
&= 2 \sum_{k=1}^{n-1} (t_{k+1} - t_k)^2 \leq 2 \|D\| \sum_{k=1}^{n-1} (t_{k+1} - t_k) = 2 \|D\| T \rightarrow 0
\end{aligned}$$

pro  $\|D\| \rightarrow 0$ .

Tedy trajektorie Wienerova procesu mají kvadratickou variaci rovnou  $T$  (všechny stejnou).

**Důsledek 5.2.5.** Trajektorie Wienerova procesu mají nekonečnou lineární variaci.

**Důsledek 5.2.6.** Trajektorie Wienerova procesu nejsou diferencovatelné na žádném podintervalu.

Pozoruhodné na předchozích výsledcích je, že na jedné straně trajektorie Wienerova procesu je náhodná, ale veličina

$$\lim_{\Delta t \rightarrow 0} \sum (\Delta W_k)^2$$

je deterministická (nezávisí na trajektorii) a rovná se  $T$  (stejná pro všechny trajektorie). To je matematický smysl heuristické formule

$$(\Delta W)^2 = \Delta t.$$

# Kapitola 6

## Itôův integrál a Itôovo lemma

### 6.1 Itôův integrál

Je-li  $f$  hladká funkce, pak můžeme přirozeně definovat integrál podle přírůstků funkce  $f$ ,

$$\int_a^b g(u) df(u) = \int_a^b g(u) f'(u) du = \lim_{\|D\| \rightarrow 0} \sum_{i=1}^n g(t_i) (f(t_i) - f(t_{i-1})),$$

kde  $a = t_0 < t_1 < \dots < t_n = b$  je dělení intervalu  $[a, b]$ . Integrál

$$\int_a^b g(u) df(u)$$

je tzv. *Stieltjesův integrál*.

Pro aplikace ve financích chceme analogický integrál podle přírůstků Wienerova procesu  $W_t$ ,

$$\int_a^b f(t, \omega) dW_t(\omega).$$

Trajektorie Wienerova procesu ale není hladká funkce, je tedy otázka jaký smysl má  $dW_t$ .

Stieltjesův a stochastický integrál se tedy liší ve dvou aspektech:

- integrál je náhodná veličina (výsledek závisí na trajektorii Wienerova procesu)
- $W_t$  není hladká, s pravděpodobností 1 nemá trajektorie derivaci v žádném bodě.

**Příklad 6.1.1.** (motivační) Nechť  $W_t(\omega)$  je cena akcie v čase  $t$  při tržním scénáři  $\omega$ . Nechť  $f(t, \omega)$  je obchodní strategie, tj. počet držených akcií v čase  $t$  za scénáře  $\omega$ . Pak

$$f(t, \omega)(W_{t+1} - W_t) = f(t, \omega) \Delta W$$

je zisk ze strategie v časovém intervalu  $[t, t+1]$ . Součtem hodnot jednotlivých zisků dostaneme v limitě integrál  $\int_a^b f dW$  který představuje zisk ze strategie v časovém intervalu  $[a, b]$ .

**Příklad 6.1.2.** (závislost na volbě vnitřního bodu) Mějme dělení intervalu  $[0, T]$ ,  $D = \{0 = t_0 < t_1 < \dots < t_n = T\}$  a nechť

$$\|D\| = \max_{j \in \{0, \dots, n-1\}} |t_{j+1} - t_j|.$$

Pro pevné  $\lambda \in [0, 1]$  položme

$$\tau_k = (1 - \lambda)t_k + \lambda t_{k+1}$$

pro  $k = 0, \dots, n-1$ . Pro  $\lambda = 0$  dostaneme levý krajní bod  $\tau_k = t_k$ , pro  $\lambda = \frac{1}{2}$  dostaneme prostředek  $\tau_k = \frac{1}{2}(t_k + t_{k+1})$  a pro  $\lambda = 1$  dostaneme pravý krajní bod  $\tau_k = t_{k+1}$ .

Definujeme *Riemannovy součty* pro

$$\int_0^T W dW$$

vztahem

$$R_n = \sum_{k=0}^{n-1} W(\tau_k)(W(t_{k+1}) - W(t_k)).$$

Dostaneme

$$\begin{aligned} W(\tau_k)(W(t_{k+1}) - W(t_k)) &= W(\tau_k)W(t_{k+1}) - W(\tau_k)W(t_k) = \\ &= W(\tau_k)W(t_{k+1}) \pm \frac{1}{2}W^2(\tau_k) \pm \frac{1}{2}W^2(t_k) \pm \frac{1}{2}W^2(t_{k+1}) - W(\tau_k)W(t_k) = \\ &= -\frac{1}{2}[W(t_{k+1}) - W(\tau_k)]^2 + \frac{1}{2}[W(\tau_k) - W(t_k)]^2 + \frac{1}{2}[W^2(t_{k+1}) - W^2(t_k)] \end{aligned}$$

Dále

$$R_n = \sum_{k=0}^{n-1} W(\tau_k)(W(t_{k+1}) - W(t_k)) = -\frac{1}{2} \sum_{k=0}^{n-1} [W(t_{k+1}) - W(\tau_k)]^2 +$$

$$+\frac{1}{2} \sum_{k=0}^{n-1} [W(\tau_k) - W(t_k)]^2 + \frac{1}{2} \sum_{k=0}^{n-1} [W^2(t_{k+1}) - W^2(t_k)].$$

Poslední člen je tzv. teleskopující součet ve kterém se všechny členy s výjimkou prvního a posledního vyruší, a rovná se tedy

$$W^2(T) - W^2(0).$$

Pro  $\|D\| \rightarrow 0$  podobně jako při výpočtu kvadratické variace máme

$$R_n = -\frac{1}{2}(1-\lambda)T + \frac{1}{2}\lambda T + \frac{1}{2}[W^2(T) - W^2(0)] = \frac{W^2(T)}{2} + \left(\lambda - \frac{1}{2}\right)T.$$

Dvě přirozené volby hodnoty  $\lambda$  vedou ke dvěma různým stochastickým integrálům:

pro  $\lambda = \frac{1}{2}$  máme  $\int_0^T W_t dW_t = \frac{W^2(T)}{2} \dots$  **Stratonovičův integrál**,

pro  $\lambda = 0$  máme  $\int_0^T W_t dW_t = \frac{W^2(T)}{2} - \frac{T}{2} \dots$  **Itôův integrál**.

Ve financích se používá jen Itôův integrál, protože portfolio musíme sestavit před pohybem ceny

## 6.2 Filtrace

Připomeňme si z diskretních modelů, že  $\sigma$ -algebra popisuje systém pozorovatelných jevů. Zachyčeje tedy informaci které jevy můžeme pozorovat a které ne.

Uvažujme standardní příklad s hodem kostkou. Pravděpodobnostní prostor  $\Omega$  má šest prvků,

$$\Omega = \{1, 2, 3, 4, 5, 6\}$$

Uvažujme nejdříve  $\sigma$ -algebru všech podmnožin  $\Omega$ . Při této  $\sigma$ -algebře jsou pozorovatelné všechny jevy. Informace kterou  $\sigma$ -algebra nese je tedy přímo hodnota která na kostce padla.

Na druhé straně, uvažujme menší systém tvořený množinami

$$\emptyset, \Omega, \{1, 3, 5\}, \{2, 4, 6\}$$

Snadno ověříme uzavřenost na sjednocení a doplňky, je to tedy opět  $\sigma$ -algebra. Při takové  $\sigma$ -algebře jsou pozorovatelné jen dva jevy, že padlo sudé číslo nebo liché číslo. Informace kterou  $\sigma$ -algebra nese je tedy pouze sudost nebo lichost hodnoty která na kostce padla.



Následující příklad připomíná použití  $\sigma$ -algeber při popisu vývoje informace v čase.

**Příklad 6.2.1.** Uvažujme tři časové okamžiky,  $t = 0, t = 1$  a  $t = 2$  a dvoukrokový model trhu. Náš pravděpodobnostní prostor je tvořen množinou všech úplných scénářů

$$\Omega = \{(++), (+-), (-+), (--)\}.$$

V čase  $t = 0$  jsou určeny pouze jevy  $\Omega$  a  $\emptyset$ , tedy  $\sigma$ -algebra popisující tuto informaci je

$$\mathcal{F}_0 = \{\emptyset, \Omega\}.$$

V čase  $t = 1$  jsou určeny jevy:  $F_+ = \{(++), (+-)\}$  a  $F_- = \{(-+), (--)\}$ . Tedy  $\sigma$ -algebra popisující tuto informaci je

$$\mathcal{F}_1 = \{\emptyset, \Omega, F_+, F_-\}.$$

V čase  $t = 2$  jsou určeny všechny jevy (každá podmnožina  $\Omega$ ), tedy  $\sigma$ -algebra popisující tuto informaci je

$$\mathcal{F}_2 = \exp \Omega = \{\forall \text{ podmnožiny } \Omega\}.$$

**Definice 6.2.2.** Systém  $\sigma$ -algeber  $\mathcal{F} = \{\mathcal{F}_t, t \in \tau\}$  na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$  se nazývá **filtrace**, pokud pro všechna  $t \in \tau$  je  $\mathcal{F}_t \subseteq \mathcal{A}$  a  $\mathcal{F}_s \subseteq \mathcal{F}_t$  kdykoliv je  $s < t$ .

**Definice 6.2.3.** Nechť  $W(t)$  je Wienerův proces na  $(\Omega, \mathcal{A}, P)$ . Filtrace  $\mathcal{F} = \{\mathcal{F}_t, t \geq 0\}$  se nazývá **historie Wienerova procesu**, jestliže pro každé  $t > 0$  je  $\mathcal{F}_t$   $\sigma$ -algebra generovaná náhodnými veličinami  $W(s, \omega)$  pro  $s \leq t$ .

$\mathcal{F}$  popisuje růst informace o trajektorii Wienerova procesu v závislosti na čase.  $\mathcal{F}_t$  je tedy informace o trajektorii v čase  $t$ . Platí

**Věta 6.2.4.**  $\mathcal{F}_t$  je nejmenší  $\sigma$ -algebra generovaná množinami typu

$$\{\omega; W(t_1, \omega) \in F_1, \dots, W(t_k, \omega) \in F_k\},$$

kde  $k = 1, 2, \dots$  a  $t_j < t$  pro všechna  $j = 1, \dots, k$  jsou libovolné časy a  $F_j \subseteq \mathbb{R}$  jsou libovolné Borelovské množiny.

**Věta 6.2.5.** Funkce  $h(\omega)$  je  $\mathcal{F}_t$ -měřitelná, kde  $\mathcal{F}$  je historie Wienerova procesu právě tehdy, když  $h$  je bodová limita součtů funkcí tvaru

$$g_1(W_1) \dots g_k(W_{t_k}),$$

kde  $g_1, \dots, g_k$  jsou omezené spojité funkce,  $t_j \leq t$  pro  $j = 1, \dots, k$  a  $k \in \mathbb{N}$ .

**Definice 6.2.6.** Nechť  $W(t)$  je Wienerův proces na prostoru  $(\Omega, \mathcal{A}, P)$  a nechť  $\mathcal{F}$  je historie Wienerova prostoru. Říkáme, že proces  $\{G(t, \omega); t \in [0, \infty)\}$  je **adaptovaný historií Wienerova procesu** (neboli  $G(t, \omega)$  je **neanticipativní**), jestliže pro každé  $t \geq 0$  je funkce  $\omega \rightarrow G(t, \omega)$   $\mathcal{F}_t$ -měřitelná.

Tedy hodnota  $G(t, \omega)$  závisí jen na historii Wienerova procesu do času  $t$ .  $G(t, \omega)$  nepředvídá proud informací reprezentovaných  $\sigma$ -algebry  $\mathcal{F}_t$ .

**Definice 6.2.7.** Stochastický proces  $S$  se nazývá **jednoduchá funkce** na intervalu  $[0, T]$ , jestliže existuje dělení  $D = \{0 = t_0 < \dots < t_m = T\}$  tak, že

$$S(t, \omega) = S_k(\omega)$$

pro  $t_k \leq t < t_{k+1}$  ( $k = 0, \dots, m-1$ ) pro nějaké náhodné veličiny  $S_k$ .

**Definice 6.2.8.** Nechť  $S$  je jednoduchá funkce. Pak

$$\int_0^T S dW = \sum_{k=0}^{m-1} S_k(\omega) (W(t_{k+1}, \omega) - W(t_k, \omega))$$

se nazývá **Itôův stochastický integrál** funkce  $S$  na intervalu  $[0, T]$ .

Tedy označíme-li  $\Delta W_k = (W(t_{k+1}, \omega) - W(t_k, \omega))$ , máme

$$\int_0^T S dW = \sum_{k=0}^{m-1} S_k \Delta W_k.$$

**Definice 6.2.9.** Nechť  $W(t)$  je Wienerův proces na prostoru  $(\Omega, \mathcal{A}, P)$ . Symbolem  $M$  budeme označovat třídu stochastických procesů

$$f(t, \omega) : [0, \infty) \times \Omega \rightarrow \mathbb{R}$$

takových, že:

- $f(t, \omega)$  je neanticipativní,
- $f(t, \omega)$  je  $\mathcal{B} \times \mathcal{A}$ -měřitelná, kde  $\mathcal{B}$  jsou Borelovské množiny na  $[0, \infty)$ ,
- platí

$$P \left\{ \int_0^T [f(t)]^2 dt < +\infty \right\} = 1$$

**Příklad 6.2.10. (Investiční strategie)** V intervalu  $[t_i, t_{i+1})$  držíme  $e_i(\omega)$  akcií, kde  $e_i(\omega)$  závisí na vývoji ceny  $W_t(\omega)$  do času  $t_i$  ( $W_t$  je cena akcie v čase  $t$ )

$$\Phi(t, \omega) = \sum_{i=0}^{m-1} e_i(\omega) \chi_{[t_i, t_{i+1})},$$

kde

$$\chi_{[t_i, t_{i+1})} = \begin{cases} 1 & \text{pro } t \in [t_i, t_{i+1}) \\ 0 & \text{jinak.} \end{cases}$$

Pak  $\Phi(t, \omega)$  je počet akcií, které držíme v čase  $t$  (za scénáře  $\omega$ ).  $\Phi$  je jednoduchá funkce. Integrál

$$\int_0^T \Phi(t, \omega) dW_t(\omega) = \sum_{i=0}^{m-1} e_i(\omega) (W_{t_{i+1}}(\omega) - W_{t_i}(\omega))$$

je náš celkový zisk z této strategie od času 0 do času  $T$ .

**Věta 6.2.11. (Itôova izometrie):** *Nechť  $S$  je jednoduchá omezená funkce (tedy  $S_k$  jsou omezené náhodné veličiny). Pak*

$$E \left[ \left( \int_0^T S(t, \omega) dW_t(\omega) \right)^2 \right] = E \left( \int_0^T S^2(t, \omega) dt \right).$$

**Důkaz:** Označme  $\Delta W_j = W(t_{j+1}, \omega) - W(t_j, \omega)$ . Máme z definice

$$\begin{aligned} E \left[ \left( \int_0^T S dW \right)^2 \right] &= E \left[ \left( \sum_{j=0}^{m-1} S_j \Delta W_j \right)^2 \right] = E \left[ \sum_{j=0}^{m-1} S_j^2 (\Delta W_j)^2 + 2 \sum_{i < j} S_i S_j \Delta W_i \Delta W_j \right] = \\ &= \sum_{j=0}^{m-1} E(S_j^2 \Delta W_j^2) + 2 \sum_{i < j} E(S_i S_j \Delta W_i) E(\Delta W_j) = \\ &= \sum_{j=0}^{m-1} E(S_j^2) E(\Delta W_j^2) = \sum_{j=0}^{m-1} E(S_j^2) (t_{j+1} - t_j) = \\ &= E \left( \sum_{j=0}^{m-1} S_j^2 (t_{j+1} - t_j) \right) = E \left[ \int_0^T S^2 dt \right]. \end{aligned}$$

Pro obecný proces  $f \in M$  definujeme  $\int_0^T f(t, \omega) dW$  limitním přechodem:

**Lemma 6.2.12.** *Nechť  $f$  je náhodný proces patřící do třídy  $M$ . Pak existuje posloupnost jednoduchých funkcí  $f_n \in M$  tak, že pro  $n \rightarrow \infty$  platí*

$$E \left( \int_0^T (f_n(t, \omega) - f(t, \omega))^2 dt \right) \rightarrow 0.$$

**Definice 6.2.13.** Pro obecný proces  $f \in M$  definujeme Itôův integrál předpisem

$$\int_0^T f(t, \omega) dW = \lim_{n \rightarrow \infty} \int_0^T f_n(t, \omega) dW.$$

Tato limita nezávisí na volbě posloupnosti  $f_n$  (důkaz je technický, pomocí Itôovy izometrie - viz literatura).

**Věta 6.2.14. (Základní vlastnosti Itôova integrálu)** Platí

1.  $\int_0^T (aG + bF) dW = a \int_0^T G dW + b \int_0^T F dW$
2.  $E \left( \int_0^T G dW \right) = 0$
3.  $\int_0^t G dW$  je  $\mathcal{F}_t$ -měřitelný

**Důkaz:** První tvrzení plyne ihned z definice. Dokážeme druhé tvrzení. Nechť  $G$  je jednoduchá funkce, tedy  $G(t, \omega) = G_k(\omega)$  pro  $t_k \leq t < t_{k+1}$ , kde  $k = 0, \dots, m-1$ . Jelikož  $G_k(\omega)$  závisí jen na  $W(s)$  pro  $s \leq t_k$  (z neanticipativnosti), dostáváme:

$$\begin{aligned} E \left( \int_0^T G dW \right) &= E \left( \sum_{k=0}^{m-1} G_k(\omega) \Delta W_k \right) = \\ &= \sum_{k=0}^{m-1} E(G_k(\omega) \Delta W_k) = \sum_{k=0}^{m-1} E(G_k(\omega)) E(\Delta W_k). \end{aligned}$$

Protože  $E(G_k(\omega)) < \infty$  a  $E(\Delta W_k) = 0$ , platí

$$\sum_{k=0}^{m-1} E(G_k(\omega)) E(\Delta W_k) = 0.$$

## 6.3 Itôovo lemma

**Motivace:** Nechť  $f$  je hladká funkce na intervalu  $[a, b]$ . Uvažujme rovnoměrné dělení intervalu  $a = t_0 < t_1 < \dots < t_n = b$ , kde  $\Delta t_i = t_{i+1} - t_i = \frac{b-a}{n}$  pro všechna  $i = 0, 1, \dots, n-1$ .

Pak platí, s využitím Taylorova polynomu

$$f(b) - f(a) = \sum_{i=0}^{n-1} f(t_{i+1}) - f(t_i) = \sum_{i=0}^{n-1} f'(t_i) \Delta t_i + \frac{1}{2} f''(t_i) (\Delta t_i)^2 + \dots$$

$f$  je hladká, tedy

$$|f''(t)| < M$$

pro nějakou konstantu  $M$  na  $[a, b]$ . Odtud

$$\left| \frac{1}{2} \sum_{i=0}^{n-1} f''(t_i) (\Delta t_i)^2 \right| \leq \sum_{i=0}^{n-1} \frac{1}{2} M \left( \frac{b-a}{n} \right)^2 = \frac{n}{2} M \frac{(b-a)^2}{n^2} \rightarrow 0$$

pro  $n \rightarrow \infty$ .

Tedy pro  $n \rightarrow \infty$ :

$$f(b) - f(a) = \lim_{n \rightarrow \infty} \sum_{i=0}^{n-1} f'(t_i) \Delta t_i = \int_a^b f'(t) dt.$$

Pro deterministický případ jsme tedy dostali Newton-Leibnitzův vzorec.

Teď uvažujme stochastické funkce. V aplikacích, cena aktiva je funkcí Wienerova procesu  $W_t$ ,

$$S_t(\omega) = f(W_t(\omega))$$

Nechť  $f$  je hladká funkce. Pak

$$\begin{aligned} f(W(b)) - f(W(a)) &= \sum_{i=0}^{n-1} f(W(t_{i+1})) - f(W(t_i)) = \\ &= \sum f'(W(t_i)) \Delta W_i + \sum \frac{1}{2} f''(W(t_i)) (\Delta W_i)^2 + \dots \end{aligned}$$

Z lemmatu o kvadratické variaci víme, že

$$\sum_{i=0}^{n-1} (\Delta W_i)^2 \rightarrow b - a$$

pro  $n \rightarrow \infty$ , tedy členy 2. řádu nelze zanedbat (vyššího řádu už ano).

Dostaneme tedy:

$$\begin{aligned} f(W(b)) - f(W(a)) &= \lim_{n \rightarrow \infty} \sum_{i=0}^{n-1} f'(W(t_i)) \Delta W_{t_i} + \frac{1}{2} f''(W(t_i)) (\Delta W_{t_i})^2 = \\ &= \int_a^b f'(W_t) dW_t + \frac{1}{2} \int_a^b f''(W(t)) dt. \end{aligned}$$

**Definice 6.3.1.** Nechť  $W_t$  je Wienerův proces na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$ . **Jednodimenzionální Itôův proces** je stochastický proces tvaru:

$$X_t(\omega) = X_0 + \int_0^t u(s, \omega) ds + \int_0^t v(s, \omega) dW_s(\omega),$$

kde  $u, v \in M$ .

Člen  $\int_0^t u(s, \omega) ds$  je obyčejný Riemannův integrál (z náhodné funkce) a  $\int_0^t v(s, \omega) dW_s(\omega)$  je Itôův stochastický intergrál.

**Poznámka.** Často se Itôův proces zapisuje v diferenciálním tvaru:

$$dX_t(\omega) = u(t, \omega) dt + v(t, \omega) dW_t(\omega),$$

což je tzv. *stochastický diferenciál*, kde koeficient  $u(t, \omega)$  se obvykle nazývá drift a  $v(t, \omega)$  je volatilita.

**Věta 6.3.2.** (*Itôovo lemma*) Nechť  $X(t, \omega)$  je Itôův proces se stochastickým diferenciálem

$$dX(t) = udt + vdW(t),$$

kde  $u, v$  jsou procesy třídy  $M$ . Nechť

$$g(t, x) : \langle 0, \infty \rangle \times \mathbb{R} \rightarrow \mathbb{R}$$

je dvakrát spojitě diferencovatelná funkce. Potom

$$Y(t) = g(t, X(t))$$

je opět Itôův proces. Jeho stochastický diferenciál má tvar

$$dY(t) = \frac{\partial g}{\partial t}(t, X(t)) dt + \frac{\partial g}{\partial x}(t, X(t)) dX(t) + \frac{1}{2} \frac{\partial^2 g}{\partial x^2}(t, X(t)) (dX(t))^2,$$

kde

$$(dX(t))^2 = (udt + vdW(t))^2 = (dX(t))(dX(t))$$

se počítá podle pravidel  $dt dt = dt dW = 0$  a  $dW dW = dt$ .

**Příklad 6.3.3.** (Stochastická diferenciální rovnice pro vývoj ceny akcie):

Ceny se vyvíjí podle geometrického Wienerova procesu

$$dS_t = \mu S_t dt + \sigma S_t dW_t$$

neboli

$$\frac{dS_t}{S_t} = \mu dt + \sigma dW_t.$$

Nechť

$$g(t, x) = \ln x$$

a

$$Y_t = g(t, S_t).$$

Máme tedy

$$\begin{aligned}\frac{\partial g}{\partial t} &= 0 \\ \frac{\partial g}{\partial x} &= \frac{1}{x} \\ \frac{\partial^2 g}{\partial x^2} &= -\frac{1}{x^2}.\end{aligned}$$

Podle Itôova lemmatu dostaneme

$$dY(t) = 0 + \frac{1}{S_t} dS_t + \frac{1}{2} \left( -\frac{1}{S_t^2} \right) (dS_t)^2,$$

kde  $(dS_t)^2 = \sigma^2 S_t^2 dt$ . Tedy

$$dY(t) = \frac{1}{S_t} (\mu S_t dt + \sigma S_t dW_t) - \frac{1}{2} \sigma^2 dt = \left( \mu - \frac{1}{2} \sigma^2 \right) dt + \sigma dW_t.$$

Odtud

$$dY_t = \left( \mu - \frac{1}{2} \sigma^2 \right) dt + \sigma dW_t,$$

tedy

$$Y_t = Y_0 + \left( \mu - \frac{\sigma^2}{2} \right) t + \sigma W_t,$$

kde  $W_0 = 0$ . Tedy

$$\ln S_t = \ln S_0 + \mu t + \sigma W_t - \frac{1}{2} \sigma^2 t$$

má normální rozdělení

$$\ln S_t \sim N \left( \ln S_0 + \mu t - \frac{1}{2} \sigma^2 t; \sigma^2 t \right)$$

a

$$S_t = S_0 e^{\mu t + \sigma W_t - \frac{1}{2} \sigma^2 t}$$

má lognormální rozdělení.

# Kapitola 7

## Martingaly a Itôovy proces

### 7.1 Definice martingalu

V diskrétním případě jsme definovali martingal takto. Posloupnost náhodných veličin  $S_n$ ,  $0 \leq n \leq \infty$ , která pro všechna  $n$  splňuje

$$E(S_{n+1} | S_0, S_1, \dots, S_n) = S_n,$$

se nazývá martingal.

Připomeňme si z předchozích kapitol dvě definice.

**Filtrace** na  $(\Omega, \mathcal{A}, P)$  je systém  $\sigma$ -algeber  $\mathcal{F} = \{\mathcal{F}_t, t \in T\}$ , kde pro každé  $t \in T$  platí  $\mathcal{F}_t \subseteq \mathcal{A}$ , a  $\mathcal{F}_s \subseteq \mathcal{F}_t$  pro  $s \leq t$ .

**Historie Wienerova procesu** je filtrace  $\mathcal{F}^W = \{\mathcal{F}_t^W, t \in T\}$  taková, že  $\mathcal{F}_t^W$  je  $\sigma$ -algebra generovaná náhodnými veličinami  $W(s)$  pro  $s \leq t$ . Popisuje růst informace o trajektorii Wienerova procesu v závislosti na čase.

Pokud bude zřejmé z kontextu že uvažovaná filtrace je historie Wienerova procesu, budeme horní index  $W$  vynechávat.

**Definice 7.1.1.** Nechť  $\{W_t; t \geq 0\}$  je Wienerův proces na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$  a  $\{\mathcal{F}_t^W, t \geq 0\}$  je historie Wienerova procesu. Stochastický proces  $M_t$  se nazývá **martingal** vzhledem k  $\mathcal{F}_t^W$ , jestliže:

–  $M_t$  je neanticipativní (tj.  $M_t$  je určeno hodnotami Wienerova procesu do času  $t$ ),

–  $E[|M_t|] < \infty$  pro  $\forall t \geq 0$ ,

– platí tzv. *Martingalová podmínka*

$$E[M_s | \mathcal{F}_t^W] = M_t$$

pro všechna  $s \geq t$ .



Řečeno slovy: “Očekávání budoucí hodnoty je rovno současné hodnotě.”

**Věta 7.1.2.** *Nechť  $\{W(t); t \geq 0\}$  je Wienerův proces na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$  a  $\{\mathcal{F}_t, t \geq 0\}$  je historie Wienerova procesu. Pak  $W(t)$  je martingalem vzhledem k  $\{\mathcal{F}_t, t \geq 0\}$ .*

**Důkaz:** Musíme dokázat všechny tři vlastnosti martingalu.  $W_t$  je neanticipativní, tedy  $W_t$  je určeno hodnotami Wienerova procesu do času  $t$  pro  $s \leq t$ . To je triviální. Dále

$$E[|W_t|] < \infty$$

kde

$$W_t \sim N(0, t)$$

a  $f = \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}}$ , tedy

$$E[|W_t|] = \int_{-\infty}^{\infty} |x| \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}} dx.$$

Jelikož jsou obě funkce v integrálu sudé, můžeme psát

$$E[|W_t|] = 2 \int_0^{\infty} x \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}} dx = 2 \frac{1}{\sqrt{2\pi t}} \int_0^{\infty} x e^{-\frac{x^2}{2t}} dx$$

Zavedeme substituci  $s = -\frac{x^2}{2t}$ ,  $ds = -\frac{1}{2t} 2x dx$  a dostáváme

$$\begin{aligned} E[|W_t|] &= 2 \frac{1}{\sqrt{2\pi t}} \int_0^{-\infty} e^s (-t) ds = 2 \frac{1}{\sqrt{2\pi t}} \int_{-\infty}^0 t e^s ds = \\ &= \frac{2t}{\sqrt{2\pi t}} \int_{-\infty}^0 e^s ds = \frac{2t}{\sqrt{2\pi t}} [e^s]_{-\infty}^0 = \frac{2t}{\sqrt{2\pi t}} (1 - e^{-\infty}) = \frac{2t}{\sqrt{2\pi t}} < \infty \end{aligned}$$

Zbývá nám dokázat, že  $E[W_s | \mathcal{F}_t] = W_t$ , pro  $s \geq t$ ,

$$\begin{aligned} E[W_s | \mathcal{F}_t] &= E[W_t + (W_s - W_t) | \mathcal{F}_t] = \\ &= E[W_t | \mathcal{F}_t] + E[W_s - W_t | \mathcal{F}_t] = W_t + 0 = W_t \end{aligned}$$

neboť  $W_s - W_t$  a  $W_t$  jsou nezávislé, tedy  $E[W_s - W_t | \mathcal{F}_t] = 0$ .

V diskrétním případě je martingalová transformace martingal. Ve spojitém případě je analogií martingalové transformace Itôův integrál. Platí

$$E\left(\int_{s_1}^{s_2} a(t, \omega) dW\right) = 0$$

pro každé  $s_1, s_2$ , odkud plyne, že Itôův integrál je martingal.

## 7.2 Itôův proces a stopping time

**Definice 7.2.1.** Nechť  $W(t)$  je standardní Wienerův proces na  $(\Omega, \mathcal{A}, P)$  a  $\{\mathcal{F}_t\}$  je historie Wienerova procesu. Nezáporná náhodná veličina  $\tau$  se nazývá **stopping time** (“čas zastavení”), jestliže pro všechna  $t \geq 0$  je událost (jev)  $\{\tau \leq t\}$  prvkem  $\sigma$ -algebry  $\mathcal{F}_t$ .

V čase  $t$  tedy víme, zda čas  $\tau$  už nastal, nebo ne.

**Příklad 7.2.2.** První čas průchodu bodem  $a$ :

Nechť  $a > 0$ ,

$$\tau_a = \min_t \{t \in (0, \infty); W(t) = a\}$$

a  $\tau_a = \infty$  pokud neexistuje  $t$  takové, že  $W(t) = a$ . Je vidět, že  $\tau_a$  je stopping time.

**Příklad 7.2.3.** Maximum na intervalu  $[0, T]$  není stopping time.

Definujeme

$$M(T) = \max_{t \in [0, T]} W(t)$$

maximální hodnotu  $W(t)$ , a

$$\tau = \min_t \{t \in [0, T], W(t) = M(T)\}$$

čas dosažení maxima. V čase  $t$  nevíme, jestli  $\tau$  nastal nebo ne (může být potom ještě vyšší hodnota), tedy nejde o stopping time.

**Věta 7.2.4. (Princip reflexe):** Nechť  $W(t)$  je Wienerův proces,  $a > 0$  a  $\tau(a)$  je čas prvního dosažení bodu  $a$ . Platí

$$P[\tau(a) < t] = 2P[W(t) > a].$$

Výraz na pravé straně rovnice umíme spočítat:

$$P[W(t) > a] = \int_a^\infty \frac{1}{\sqrt{2\pi t}} e^{-\frac{x^2}{2t}} dx.$$

**Důkaz:** Je-li  $W(t) > a$ , pak ze spojitosti trajektorií Wienerova procesu plyne, že  $\tau(a) < t$ . Protože  $\tau(a)$  je stopping time,

$$W(t + \tau(a)) - W(\tau(a))$$

je Wienerův proces, který je nezávislý na vývoji před časem  $\tau(a)$ . Tedy

$$W(t) - W(\tau(a)) \sim N(0, t - \tau(a))$$

Ze symetrie normálního rozdělení plyne

$$P[W(t) - W(\tau(a)) > 0 \mid \tau(a) < t] = P[W(t) - W(\tau(a)) < 0 \mid \tau(a) < t] = \frac{1}{2}.$$

Tedy

$$\begin{aligned} P[W(t) > a] &= P[\tau(a) < t \wedge W(t) - W(\tau(a)) > 0] = \\ &= P[\tau(a) < t] P[W(t) - W(\tau(a)) > 0 \mid \tau(a) < t] = \frac{1}{2} P[\tau(a) < t] \end{aligned}$$

Celkem

$$P[\tau(a) < t] = 2P[W(t) > a].$$

**Poznámka.** Pokud víme, že  $\tau(a) < t$ , pak je stejná pravděpodobnost, že se  $W(t)$  nachází na úrovni  $a$  jako pod úrovní  $a$ .

# Kapitola 8

## Cameron-Martinova věta

### 8.1 Radon-Nikodýmova derivace

Při oceňování složitějších typů opcí závislých na cestě je potřeba tzv. Cameron-Martinova věta (nebo její obecnější verze Girsanova věta).

Nechť  $W(t)$  je standardní Wienerův proces na  $(\Omega, \mathcal{A}, P)$ .

Nechť  $\widetilde{W}$  je Wienerův proces s driftem,

$$\widetilde{W}(t) = W(t) + \gamma t$$

pro nějakou reálnou konstantu  $\gamma \neq 0$ . Chceme najít pravděpodobnostní míru  $Q$  na  $\Omega$  tak, aby  $\widetilde{W}(t)$  byl obyčejný Wienerův proces na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, Q)$ .

**Poznámka:** Prostor  $\Omega$ , který často ani není explicitně zadán, můžeme ztotožnit s prostorem všech trajektorií Wienerova procesu, tedy s prostorem všech spojitých funkcí na intervalu  $[0, T]$ . Změna míry je tedy proces který mění pravděpodobnost jednotlivých trajektorií (přesně řečeno jejich okolí).

Radon-Nikodýmova derivace  $Q$  vůči  $P$ , označovaná  $\frac{dQ}{dP}$ , umožňuje převádět jednu pravděpodobnostní míru na jinou.

**Definice 8.1.1.** Nechť  $(\Omega, \mathcal{A})$  je pravděpodobnostní prostor, na kterém jsou dány dvě pravděpodobnostní míry  $P$  a  $Q$ . Říkáme, že  $P$  a  $Q$  jsou **ekvivalentní**, jestliže platí  $P(A) = 0 \iff Q(A) = 0$ .

**Definice 8.1.2.** Nechť  $P$  a  $Q$  jsou ekvivalentní míry na  $(\Omega, \mathcal{A})$  a pro náhodnou veličinu  $Z = \frac{dQ}{dP}$  platí

$$E_Q(X) = \int_{\Omega} X dQ = \int_{\Omega} X \frac{dQ}{dP} dP =$$

$$= \int_{\Omega} XZ dP = E_P(XZ) = E_P \left[ \frac{dQ}{dP} X \right],$$

pak  $Z$  se nazývá **Radon-Nikodýmova derivace** pravděpodobnostní míry  $Q$  vzhledem k pravděpodobnostní míře  $P$ .

## 8.2 Cameron-Martinova věta

**Věta 8.2.1. (Cameron-Martin):** *Nechť  $\{W(t) : t \in [0, T]\}$  je standardní Wienerův proces na pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$ . Nechť  $Q$  je pravděpodobnostní míra, jejíž Radon-Nikodýmova derivace vzhledem k  $P$  je*

$$\frac{dQ}{dP}(\omega) = \exp \left( -\gamma W(T, \omega) - \frac{1}{2} \gamma^2 T \right).$$

*Pak  $\widetilde{W}(t) = W(t) + \gamma t$  je Wienerův proces (a tedy marginal) vzhledem ke  $Q$ .*

Je-li například  $\gamma < 0$ , pak vzhledem k míře  $Q$  je pravěpodobnost trajektorie tím větší, čím je větší její hodnota v čase  $T$  (viz. obrázek u hesla Girsanovova věta na wikipedii). Opravdu, v Radon-Nikodýmově derivaci druhý člen v exponentu nezávisí na trajektorii a první je přímo úměrný hodnotě procesu v bodě  $T$ .

K důkazu je třeba moment generující funkce, připomeneme její definici.

**Definice 8.2.2. Moment generující funkce** náhodné veličiny  $X$  je definován jako

$$\psi(\theta) = E[e^{\theta X}] = \int_{\mathbb{R}} e^{\theta x} f(x) dx,$$

kde  $f$  je hustota  $X$ .

**Lemma 8.2.3.** *Nechť  $X$  je náhodná veličina s rozdělením*

$$N(0, \sigma^2)$$

*a  $\theta$  je parametr. Pak*

$$E(e^{\theta X}) = e^{\frac{1}{2}\theta^2\sigma^2}.$$

**Důkaz:**

$$E(e^{\theta X}) = \int_{-\infty}^{\infty} e^{\theta x} dF(x) = \int_{-\infty}^{\infty} e^{\theta x} \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} dx = \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} e^{\theta x - \frac{x^2}{2\sigma^2}} dx.$$

Doplníme na čtverec v exponentu,

$$\begin{aligned} E(e^{\theta X}) &= \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} e^{-\left[\frac{x^2}{2\sigma^2} - \theta x\right]} dx = \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} e^{-\left[\frac{x}{\sqrt{2\sigma}} - \frac{\theta\sqrt{2\sigma}}{2}\right]^2 + \frac{\theta^2\sigma^2}{2}} dx = \\ &= \frac{1}{\sqrt{2\pi\sigma}} e^{\frac{\theta^2\sigma^2}{2}} \int_{-\infty}^{\infty} e^{-\left[\frac{x}{\sqrt{2\sigma}} - \frac{\theta\sqrt{2\sigma}}{2}\right]^2} dx = e^{\frac{\theta^2\sigma^2}{2}}, \end{aligned}$$

protože

$$\frac{1}{\sqrt{2\pi\sigma}} e^{-\left[\frac{x}{\sqrt{2\sigma}} - \frac{\theta\sqrt{2\sigma}}{2}\right]^2}$$

je hustota  $N\left(\frac{\theta\sqrt{2\sigma}}{2}; \sigma^2\right)$ , jejíž integrál přes celou reálnou osu je roven jedné.

**Důkaz Cameron-Martinovy věty:** Chceme dokázat, že

$$\widetilde{W}(t) = W(t) + \gamma t$$

je standardní Wienerův proces vůči pravděpodobnostní míře  $Q$ , kde

$$\frac{dQ}{dP}(\omega) = \exp\left(-\gamma W(T, \omega) - \frac{1}{2}\gamma^2 T\right).$$

Musíme dokázat vlastnosti Wienerova procesu vzhledem ke  $Q$ . Máme

$$\widetilde{W}(0) = W(0) + \gamma 0 = 0.$$

Spojitosť trajektorií plyne ze spojitosti trajektorií  $W(t)$  a spojitosti funkce  $\gamma t$ . Dále s využitím přechozího lemmatu dokážeme, že  $\widetilde{W}(t)$  má vůči  $Q$  rozdělení  $N(0, t)$ . Víme, že moment generující funkce určuje jednoznačně pravděpodobnostní rozdělení. Vypočteme moment generující funkce  $\widetilde{W}(t)$  vůči  $Q$ ,

$$\begin{aligned} E_Q\left(e^{\theta\widetilde{W}(t)}\right) &= E_P\left(\frac{dQ}{dP}e^{\theta\widetilde{W}(t)}\right) = E_P\left[e^{-\gamma W(T) - \frac{1}{2}\gamma^2 T + \theta(W(t) + \gamma t)}\right] = \\ &= e^{-\frac{1}{2}\gamma^2 T + \theta\gamma t} E_P\left(e^{-\gamma W(T) + \theta W(t)}\right) = e^{-\frac{1}{2}\gamma^2 T + \theta\gamma t} E_P\left(e^{-\gamma(W(T) - W(t)) - \gamma W(t) + \theta W(t)}\right). \end{aligned}$$

Víme, že  $W(t)$  a  $W(T) - W(t)$  jsou nezávislé (z definice Wienerova procesu). Tedy

$$\begin{aligned}
& e^{-\frac{1}{2}\gamma^2 T + \theta\gamma t} E_P \left( e^{-\gamma(W(T)-W(t)) - \gamma W(t) + \theta W(t)} \right) = \\
& = e^{-\frac{1}{2}\gamma^2 T + \theta\gamma t} E_P \left( e^{-\gamma(W(T)-W(t))} \right) E_P \left( e^{(\theta-\gamma)W(t)} \right).
\end{aligned}$$

Použitím předchozího lemmatu s hodnotami  $\sigma^2 = t$  respektive  $\sigma^2 = T - t$ , je tedy výraz roven

$$e^{-\frac{1}{2}\gamma^2 T + \theta\gamma t} e^{\frac{\gamma^2}{2}(T-t)} e^{\frac{(\theta-\gamma)^2}{2}t} = e^{\frac{\theta^2}{2}t},$$

neboť

$$-\frac{1}{2}\gamma^2 T + \theta\gamma t + \frac{\gamma^2}{2}T - \frac{\gamma^2}{2}t + \frac{\theta^2}{2}t - \theta\gamma t + \frac{\gamma^2}{2}t = \frac{\theta^2}{2}t.$$

To je ale moment generující funkce  $N(0, t)$ . Zcela analogicky se dokáže, že

$$\widetilde{W}(s) - \widetilde{W}(t)$$

má rozdělení  $N(0, s - t)$  pro  $s > t$  vůči  $Q$ .

### 8.3 Girsanovova věta

Girsanovova věta zobecňuje Cameron-Martinovu větu na případ obecného driftu.

**Věta 8.3.1. (Girsanov):** *Nechť  $W(t, \omega)$ ,  $0 \leq t \leq T$  je Wienerův proces na  $(\Omega, \mathcal{A}, P)$ . Nechť  $\gamma(t, \omega)$  je adaptovaný proces vzhledem k historii Wienerova procesu, pro který*

$$E_P \left[ \exp \left( \frac{1}{2} \int_0^T \gamma(t) dt \right) \right] < \infty.$$

*Pak existuje pravděpodobnostní míra  $Q$  na  $(\Omega, \mathcal{A})$  taková, že platí  $Q \sim P$ ,*

$$\frac{dQ}{dP}(\omega) = \exp \left( - \int_0^T \gamma(t, \omega) dW(t, \omega) - \frac{1}{2} \int_0^T \gamma^2(t, \omega) dt \right)$$

*a*

$$\widetilde{W}(t, \omega) = W(t, \omega) + \int_0^T \gamma(s, \omega) ds$$

*je Wienerův proces vzhledem ke  $Q$ .*

**Věta 8.3.2. (obrácená Girsanovova věta):** *Nechť  $W(t, \omega)$ ,  $0 \leq t \leq T$*

je Wienerův proces na  $(\Omega, \mathcal{A}, P)$ . Nechť  $Q \sim P$ . Pak existuje adaptovaný proces  $\gamma(t, \omega)$  takový, že

$$\widetilde{W}(t, \omega) = W(t, \omega) + \int_0^t \gamma(s, \omega) ds$$

je Wienerův proces na  $(\Omega, \mathcal{A}, Q)$ . Navíc

$$\frac{dQ}{dP} = \exp \left( - \int_0^T \gamma(t, \omega) dW(t, \omega) - \frac{1}{2} \int_0^T \gamma^2(t, \omega) dt \right).$$



## Kapitola 9

# Odvození Black-Scholesovy rovnice

Black-Scholesova rovnice je důsledkem modelu vývoje ceny akcie pomocí Wienerova procesu. Předpokládejme, že pohyb ceny akcie je popsán geometrickým Wienerovým procesem,

$$dS = \mu S dt + \sigma S dW,$$

neboli

$$\frac{dS}{S} = \mu dt + \sigma dW.$$

Použijeme Itôovo lemma na funkci  $G(S, t) = \ln S$ . Máme  $\frac{\partial G}{\partial t} = 0$ ,  $\frac{\partial G}{\partial S} = \frac{1}{S}$  a  $\frac{\partial^2 G}{\partial S^2} = -\frac{1}{S^2}$ . Tedy z Itôova lemmatu

$$dG = \left( \mu - \frac{\sigma^2}{2} \right) dt + \sigma dW$$

a

$$d(\ln S) = \left( \mu - \frac{\sigma^2}{2} \right) dt + \sigma dW.$$

Z toho plyne, že  $\ln S_T - \ln S_0$  má normální rozdělení se střední hodnotou  $\left( \mu - \frac{\sigma^2}{2} \right) T$  a rozptylem  $\sigma^2 T$ . Tedy

$$\ln S_T \sim N \left( \ln S_0 + \left( \mu - \frac{\sigma^2}{2} \right) T; \sigma^2 T \right).$$

$S_T$  má tedy **lognormální rozdělení** ( $\ln S_T$  má normální rozdělení).

## 9.1 Black-Scholesova rovnice

V následujícím odvození budeme předpokládat existenci bezrizikového aktiva s úrokovou mírou  $r$ .

Vyjdeme z rovnice pro cenu akcie, která sleduje geometrický Wienerův proces

$$dS = \mu S dt + \sigma S dW. \quad (9.1)$$

Nechť  $V$  je cena evropské call opce s danou realizační cenou  $K$  a časem expirace  $T$ . Zisk z takové opce v čase  $T$  je tedy  $(S_T - K)_+$ .  $V$  závisí na  $S$  a  $t$  a je tedy funkcí dvou proměnných  $V(S, t)$ . Hodnota  $V(S, t)$  je cena opce v čase  $t$  v situaci, kdy cena akcie je rovna  $S$ .

Z Itôova lemmatu máme

$$dV = \frac{\partial V}{\partial t} dt + \frac{\partial V}{\partial S} dS + \frac{1}{2} \frac{\partial^2 V}{\partial S^2} (dS)^2.$$

Za  $dS$  dosadíme ze 9.1, tedy

$$dV = \frac{\partial V}{\partial t} dt + \frac{\partial V}{\partial S} (\mu S dt + \sigma S dW) + \frac{1}{2} \frac{\partial^2 V}{\partial S^2} (\mu S dt + \sigma S dW)^2.$$

Podle Itôova lemmatu  $(dt)^2$  a  $dt dW$  jsou členy vyššího řádu za které dosadíme nulu, zatímco  $(dW)^2 = dt$ . Dostáváme tedy

$$dV = \left( \frac{\partial V}{\partial t} + \frac{\partial V}{\partial S} \mu S + \frac{1}{2} \frac{\partial^2 V}{\partial S^2} \sigma^2 S^2 \right) dt + \frac{\partial V}{\partial S} \sigma S dW. \quad (9.2)$$

Vhodnou kombinací 9.1 a 9.2 můžeme sestavit portfolio z akcií a opcí, jehož výnos za čas  $dt$  je deterministický. Jinak řečeno, můžeme eliminovat stochastický člen  $dW$ .

Označme  $\Pi$  hodnotu portfolio složeného z 1 opce a  $-\frac{\partial V}{\partial S}$  akcie, tedy

$$\Pi = -\frac{\partial V}{\partial S} S + 1V$$

Pro přírůstek hodnoty portfolio za čas  $dt$  máme:

$$d\Pi = \left( -\frac{\partial V}{\partial S} \right) dS + 1df.$$

Po dosazení z 9.1 dostaneme

$$d\Pi = \left( -\frac{\partial V}{\partial S} \mu S + \frac{\partial V}{\partial t} + \frac{\partial V}{\partial S} \mu S + \frac{1}{2} \frac{\partial^2 V}{\partial S^2} \sigma^2 S^2 \right) dt,$$

stochastický člen se vyruší.

$d\Pi$  se musí (z neexistence arbitráže) rovnat zisku z bezrizikového aktiva s úrokovou mírou  $r$ , tedy

$$d\Pi = r\Pi dt.$$

Dosazením dostaneme

$$\left( \frac{\partial V}{\partial t} + \frac{1}{2} \frac{\partial^2 V}{\partial S^2} \sigma^2 S^2 \right) dt = r \left( -\frac{\partial V}{\partial S} S + V \right) dt,$$

tedy

$$\frac{\partial V}{\partial t} + \frac{1}{2} \frac{\partial^2 V}{\partial S^2} \sigma^2 S^2 + \frac{\partial V}{\partial S} S r = rV.$$

To je *Black-Scholesova parciální diferenciální rovnice*.

Po vhodných transformacích proměnných dostaneme rovnici vedení tepla (rovnici difuze)

$$\frac{\partial V}{\partial t} = \frac{\partial^2 V}{\partial S^2}$$

Řešením společně s příslušnou podmínkou (známe hodnotu  $V(T) = (S_T - K)_+$ ) dostaneme Black-Scholesův vzorec.

# Kapitola 10

## Black-Scholesův model

V této kapitole odvodíme Black-Scholesův vzorec za obecnějšího předpokladu než v minulé kapitole. Budeme uvažovat úrokovou míru měnící se v čase.

### 10.1 Předpoklady Black-Scholesova modelu

Předpokládejme, že na trhu existují dvě aktiva,

- bezrizikový dluhopis, jehož cena v čase  $t$  je  $B_t$ .
- riziková akcie, jejíž cena v čase  $t$  je  $S_t$ .  $S_0$  je cena v současnosti, tedy známá hodnota.

Dluhopis má známou úrokovou míru  $r_t$ , kde  $r_t$  je deterministická funkce času. Tedy cena dluhopisu  $B_t$  v čase  $t$  splňuje

$$\frac{dB_t}{dt} = r_t B_t.$$

Řešením (separací proměnných) dostaneme:

$$\frac{dB_t}{B_t} = r_t dt.$$

Tedy  $\ln B_t = \int r_t dt$  a

$$B_t = \exp\left(\int_0^t r_s ds\right).$$

Cena podílu akcie se řídí stochastickou diferenciální rovnicí tvaru

$$dS_t = \mu_t S_t dt + \sigma S_t dW_t \quad (10.1)$$

kde  $W_t$  je standardní Wienerův proces,  $\mu_t$  je deterministická funkce času a  $\sigma > 0$  je konstanta nazývaná volatilita akcie.

## 10.2 Odvození ceny evropské call opce

Vyjdeme z předpokladu neexistence arbitráže.

**Věta 10.2.1. (Základní věta arbitrážní teorie):** Pokud neexistuje na trhu arbitráž, potom existuje rovnovážná (risk-neutrální) pravděpodobnostní míra na prostoru tržních scénářů, vůči níž je proces diskontované ceny akcie martingal. Speciálně

$$S_0^* = E(S_t^*),$$

kde  $S_t^*$  je diskontovaná cena v čase  $t$ .

**Věta 10.2.2.** Nechť koeficient driftu  $\mu_t$  je omezený. Pak stochastická diferenciální rovnice (10.1) má řešení

$$S_t = S_0 \exp\left(\sigma W_t - \frac{\sigma^2}{2}t + \int_0^t \mu_s ds\right).$$

Navíc, vzhledem k risk-neutrální míře musí platit  $r_t = \mu_t$ .

**Důkaz:** Použijeme Itôovu formuli na funkci

$$g(x, t) = \exp\left(\sigma x - \frac{\sigma^2}{2}t + \int_0^t \mu_s ds\right)$$

a podkladový proces  $X = W$ .

Pro  $S = g(x, t)$  dostaneme

$$dS = \sigma S dW + \mu_t S dt.$$

Tedy  $S$  řeší rovnici (10.1).

Dále víme, že vzhledem k risk-neutrální míře diskontovaný proces ceny akcie musí být martingal. Diskontovací faktor je cena bezrizikového dluhopisu  $B_t$ , tedy

$$S_t^* = \frac{S_t}{B_t} = \frac{\exp\left(\sigma W_t - \frac{\sigma^2}{2}t + \int_0^t \mu_s ds\right)}{\exp\left(\int_0^t r_s ds\right)} = \exp\left(\sigma W_t - \frac{\sigma^2}{2}t + \int_0^t (\mu_s - r_s) ds\right).$$

Dále, stejnou aplikací Itôova lemmatu dostaneme, že  $S_t^*$  splňuje stochastickou diferenciální rovnici

$$dS_t^* = \sigma S_t^* dW_t + S_t^* (\mu_t - r_t) dt.$$

Víme, že  $S_t^*$  je martingal právě tehdy, když koeficient u  $dt$  je identicky roven nule, tedy  $r_t = \mu_t$  pro všechna  $t$ .

**Důsledek 10.2.3.** Vzhledem k rovnovážné pravděpodobnostní míře (tedy pro  $r_t = \mu_t$ ) logaritmus diskontované ceny akcie  $S_t^*$  v čase  $t$  má normální rozdělení se střední hodnotou  $\ln S_0 - \frac{\sigma^2}{2}t$  a rozptylem  $\sigma^2t$ .

## 10.3 Odvození Black-Scholesova vzorce pro evropskou call opci

Evropská call opce na akcii s realizační cenou  $K$  a časem expirace  $T$  dává majiteli právo koupit v čase  $T$  akcii za cenu  $K$ . Tedy hodnota opce v čase  $T$  je

$$V_T = (S_T - K)_+ = \begin{cases} S_T - K & \text{pro } S_T \geq K \\ 0 & \text{pro } S_T < K \end{cases}$$

Zajímá nás současná cena opce  $V_0$ . Podle základní věty arbitrážní teorie plyne, že pokud na trhu neexistuje arbitráž, pak cena opce v čase  $t = 0$  musí být rovna diskontovanému očekávání vzhledem k rovnovážné pravděpodobnostní míře její hodnoty v čase  $T$ . Podle předchozí věty tedy platí

$$V_0(S_0, K, T) = E_Q \left( S_T^* - \frac{K}{B_T} \right)_+,$$

kde  $S_T^* = \frac{S_T}{B_T}$ ,  $B_T$  je cena dluhopisu v čase  $T$  a  $S_T^*$  má rozdělení podle důsledku předchozí věty vzhledem k risk neutrální míře  $Q$ .

Výpočtem očekávání dostaneme Black-Scholesův vzorec

$$V(S_0, K, T) = S_0 \phi(z) - \frac{K}{B_T} \phi\left(z - \sigma\sqrt{T}\right),$$

kde

$$z = \frac{\ln\left(S_0 \frac{B_T}{K}\right) + \sigma^2 \frac{T}{2}}{\sigma\sqrt{T}}$$

a  $\phi$  je distribuční funkce normálního rozdělení:

$$\phi(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx.$$

Pro výpočet příslušného očekávání připomeňme že

$$V_0 = E_Q \left( S_T^* - \frac{K}{B_T} \right)_+,$$

kde

$$S_T^* = \frac{S_T}{B_T}$$

a

$$\ln S_T^* \sim N\left(\ln S_0 - \frac{\sigma^2}{2}T; \sigma^2T\right).$$

Jinak řečeno,  $S_T^* = S_0 e^X$ , kde  $X \sim N\left(-\frac{\sigma^2}{2}T; \sigma^2T\right)$ .

Tedy

$$V_0 = \int_{-\infty}^{\infty} \left(S_0 e^x - \frac{K}{B_T}\right)_+ \frac{1}{\sqrt{2\pi\sigma^2T}} e^{-\frac{(x+\frac{\sigma^2}{2}T)^2}{2\sigma^2T}} dx$$

Určíme skutečný obor integrace (kde je integrovaná funkce nenulová):

$$S_0 e^x - \frac{K}{B_T} \geq 0 \iff e^x \geq \frac{K}{S_0 B_T} \Rightarrow x \geq \ln \frac{K}{S_0 B_T}.$$

Označme  $M = \ln \frac{K}{S_0 B_T}$ . Pak

$$V_0 = S_0 \int_M^{\infty} e^x \frac{1}{\sqrt{2\pi\sigma^2T}} e^{-\frac{(x+\frac{\sigma^2}{2}T)^2}{2\sigma^2T}} dx - \frac{K}{B_T} \int_M^{\infty} \frac{1}{\sqrt{2\pi\sigma^2T}} e^{-\frac{(x+\frac{\sigma^2}{2}T)^2}{2\sigma^2T}} dx.$$

V prvním integrálu doplníme v exponentu na čtverec:

$$\begin{aligned} x - \frac{(x + \frac{\sigma^2}{2}T)^2}{2\sigma^2T} &= \frac{2\sigma^2Tx - (x + \frac{\sigma^2}{2}T)^2}{2\sigma^2T} = \\ &= \frac{2\sigma^2Tx - x^2 - 2x\frac{\sigma^2}{2}T - \left(\frac{\sigma^2}{2}T\right)^2}{2\sigma^2T} = -\frac{\left(x - \frac{\sigma^2}{2}T\right)^2}{2\sigma^2T} \end{aligned}$$

a dostáváme:

$$\begin{aligned} V_0 &= S_0 \int_M^{\infty} \frac{1}{\sqrt{2\pi\sigma^2T}} e^{-\frac{(x-\frac{\sigma^2}{2}T)^2}{2\sigma^2T}} dx - \frac{K}{B_T} \int_M^{\infty} \frac{1}{\sqrt{2\pi\sigma^2T}} e^{-\frac{(x+\frac{\sigma^2}{2}T)^2}{2\sigma^2T}} dx = \\ &= S_0 P(Z_1 \geq M) - \frac{K}{B_T} P(Z_2 \geq M), \end{aligned}$$

kde

$$Z_1 \sim N\left(\frac{1}{2}\sigma^2T; \sigma^2T\right)$$

a

$$Z_2 \sim N\left(-\frac{1}{2}\sigma^2T; \sigma^2T\right).$$

Tedy celkem

$$V_0 = S_0 P\left(\frac{Z_1 - \frac{1}{2}\sigma^2T}{\sigma\sqrt{T}} \geq \frac{M - \frac{1}{2}\sigma^2T}{\sigma\sqrt{T}}\right) - \frac{K}{B_T} P\left(\frac{Z_2 + \frac{1}{2}\sigma^2T}{\sigma\sqrt{T}} \geq \frac{M + \frac{1}{2}\sigma^2T}{\sigma\sqrt{T}}\right)$$

S využitím  $1 - \phi(M) = \phi(-M)$  dostaneme:

$$V_0 = S_0 \phi\left(\frac{-M + \frac{1}{2}\sigma^2 T}{\sigma\sqrt{T}}\right) - \frac{K}{B_T} \phi\left(\frac{-M - \frac{1}{2}\sigma^2 T}{\sigma\sqrt{T}}\right),$$

což už je Black-Scholesův vzorec.



# Kapitola 11

## Rovnice vedení tepla a Wienerův proces

### 11.1 Řešení rovnice vedení tepla na přímce

Budeme se zabývat rovnicí vedení tepla na přímce,

$$u_t(x, t) = u_{xx}(x, t)$$

pro  $x \in \mathbb{R}$  a  $t \geq 0$ , kde  $u(x, t)$  je teplota v bodě  $x$  a čase  $t$ . Teplota v počátečním čase je známa, je daná počáteční podmínkou

$$u(x, 0) = \psi(x).$$

Pro každé pevné  $t > 0$  budeme uvažovat Fourierovu transformaci funkce  $u$  v proměnné  $x$ . Na jedné straně máme

$$\widehat{\left(\frac{\partial^2 u}{\partial x^2}\right)}(\xi, t) = (i\xi)^2 \hat{u}(\xi, t),$$

na druhé straně  $t$  hraje při integraci v definici Fourierovy transformace roli parametru, tedy je

$$\widehat{\left(\frac{\partial u}{\partial t}\right)}(\xi, t) = \frac{\partial \hat{u}}{\partial t}(\xi, t).$$

Transformovaná rovnice má tedy tvar

$$\frac{\partial \hat{u}}{\partial t}(\xi, t) = -\xi^2 \hat{u}(\xi, t).$$

Pro pevné  $\xi$  je to obyčejná diferenciální rovnice v proměnné  $t$ , kterou umíme vyřešit,

$$\hat{u}(\xi, t) = C e^{-\xi^2 t},$$

kde  $C = \hat{u}(\xi, 0)$ . Z počáteční podmínky tedy

$$C = \hat{\psi}(\xi).$$

Celkem

$$\hat{u}(\xi, t) = \hat{\psi}(\xi)e^{-\xi^2 t}.$$

Zpětnou transformací, podle pravidla o transformaci konvoluce dostaneme

$$u(x, t) = (\psi * G_t)(x, t),$$

kde  $G_t(x)$  je zpětná transformace funkce  $e^{-\xi^2 t}$ . Tu najdeme ze znalosti transformace Gaussovy funkce a lemmatu o transformaci po změně měřítka, kde vezmeme  $R = \frac{1}{\sqrt{2t}}$ . Dostaneme tedy

$$G_t(x) = \frac{1}{\sqrt{4\pi t}} e^{-\frac{x^2}{4t}},$$

což je tzv. Gaussovo jádro. Řešení počáteční úlohy pro rovnici vedení tepla má tedy tvar

$$u(x, t) = \frac{1}{\sqrt{4\pi t}} \int_{-\infty}^{\infty} e^{-\frac{(x-y)^2}{4t}} \psi(y) dy.$$

## 11.2 Souvislost řešení rovnice vedení tepla a Wienerova procesu

Z definice Wienerova procesu víme, že

$$P\{W(t+s) = y \mid W(s) = x\} \sim \frac{1}{\sqrt{2\pi t}} e^{-\frac{(y-x)^2}{2t}}.$$

Tato funkce je zároveň Gaussovo jádro pro modifikovanou rovnici vedení tepla (s konstantou  $\frac{1}{2}$  před druhou derivací).

**Věta 11.2.1.** *Nechť  $f : \mathbb{R} \rightarrow \mathbb{R}$  je omezená funkce. Pak jednoznačné řešení  $u(t, x)$  počáteční úlohy pro rovnici vedení tepla:*

$$\frac{\partial u}{\partial t} = \frac{1}{2} \frac{\partial^2 u}{\partial x^2}$$

kde  $u(t, x)$  je teplota v bodě  $x$  a čase  $t$  a

$$u(0, x) = f(x)$$

je počáteční podmínka, je rovno

$$u(t, x) = Ef(W_t^x) = \int_{-\infty}^{\infty} P_t(x, y) f(y) dy,$$

kde  $P_t(x, y)$  je Gaussovo jádro:

$$P_t(x, y) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{(y-x)^2}{2t}}$$

a  $W_t^x$  je Wienerův proces začínající v bodě  $x$  (místo nuly).

**Důkaz:** Stačí dokázat, že  $P_t(x, y)$  řeší rovnici vedení tepla (\*) pro každé  $y$ . To, že konvoluce s počáteční podmínkou (tedy vlastně lineární kombinace těchto řešení) je také řešením pak plyne derivováním integrálu podle parametru. Máme

$$\frac{\partial}{\partial t} (P_t(x, y)) = \frac{1}{\sqrt{2\pi}} \left(-\frac{1}{2}\right) (t)^{-\frac{3}{2}} e^{-\frac{(x-y)^2}{2t}} + \frac{1}{\sqrt{2\pi t}} e^{-\frac{(x-y)^2}{2t}} t^{-2} \left(-\frac{(x-y)^2}{2}\right)$$

$$\frac{\partial}{\partial x} (P_t(x, y)) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{(x-y)^2}{2t}} \left(-\frac{x-y}{t}\right)$$

$$\frac{\partial^2}{\partial x^2} (P_t(x, y)) = \frac{1}{\sqrt{2\pi t}} e^{-\frac{(x-y)^2}{2t}} \left(-\frac{x-y}{t}\right)^2 + \frac{1}{\sqrt{2\pi t}} e^{-\frac{(x-y)^2}{2t}} \left(-\frac{1}{t}\right)$$

Tedy

$$\frac{\partial^2}{\partial x^2} (P_t(x, y)) = 2 \frac{\partial}{\partial t} (P_t(x, y))$$

Splnění počáteční podmínky plyne okamžitě z definice funkce  $u$ .

## 11.3 Feynman-Kacova formule

Uvažujme parciální diferenciální rovnici:

$$\frac{\partial f}{\partial t} + \mu(x, t) \frac{\partial f}{\partial x} + \frac{1}{2} \sigma^2(x, t) \frac{\partial^2 f}{\partial x^2} = 0$$

(tzv. zpětná Kolmogorova rovnice). s koncovou podmínkou

$$f(x, T) = \psi(x),$$

kde  $\mu, \sigma, \psi$  jsou dané funkce a  $T$  je pevně daný čas,  $T > 0$ .

Pro  $\mu \equiv 0$  a  $\sigma^2 \equiv 1$  dostaneme

$$\frac{\partial f}{\partial t} = -\frac{1}{2} \frac{\partial^2 f}{\partial x^2}$$

tedy zpětnou rovnicí vedení tepla. **Věta 11.3.1. (Feynman-Kac):** Řešení je dáno očekáváním

$$f(x, t) = E(\psi(X_T) \mid X_t = x),$$

kde  $X$  je Itôův proces daný rovnicí

$$dX = \mu(X, t) dt + \sigma(X, t) dW.$$

**Důkaz:** Nechť  $f$  je řešení parciální diferenciální rovnice. Použijeme Itôovo lemma na funkci  $f(x, t)$  a podkladový proces  $X$ . Dostaneme

$$df(X, t) = \left( \mu(X, t) \frac{\partial f}{\partial x} + \frac{\partial f}{\partial t} + \frac{1}{2} \sigma^2(X, t) \frac{\partial^2 f}{\partial x^2} \right) dt + \sigma(X, t) \frac{\partial f}{\partial x} dW,$$

kde

$$\left( \mu(X, t) \frac{\partial f}{\partial x} + \frac{\partial f}{\partial t} + \frac{1}{2} \sigma^2(X, t) \frac{\partial^2 f}{\partial x^2} \right) = 0,$$

neboť  $f$  řeší parciální diferenciální rovnici. Dále integrováním dostaneme

$$\int_t^T df = f(X_T, T) - f(X_t, t) = \int_t^T \sigma(X, t) \frac{\partial f}{\partial x} dW.$$

Vezmeme očekávání (za podmínky  $X_t = x$ ). Víme, že

$$E \left( \int_t^T \sigma(X, t) \frac{\partial f}{\partial x} dW \right) = 0$$

(základní vlastnost Itôova integrálu) Tedy ze vztahu

$$E(f(X_T, T) - f(X_t, t)) = 0$$

máme

$$f(x, t) = E[f(X_t, t) \mid X_t = x] = E[f(X_T, T) \mid X_t = x] = E[\psi(X_T) \mid X_t = x],$$

což jsme chtěli dokázat.

# Kapitola 12

## Bariérové opce

Nejjednodušší typ opce, kde výplata závisí na celém vývoji ceny akcie, nikoliv jenom na ceně akcie v době realizace je bariérová opce.

Máme čtyři základní typy bariérových opcí:

- ***up and in*** ... opce je bezcenná, pokud hodnota akcie v čase  $[0, T]$  nepřekročí hodnotu  $A$ .
- ***down and in*** ... opce je bezcenná, pokud hodnota akcie v čase  $[0, T]$  neklesne pod hodnotu  $a$ .
- ***up and out*** ... opce je bezcenná, pokud hodnota akcie v čase  $[0, T]$  překročí hodnotu  $A$ .
- ***down and out*** ... opce je bezcenná, pokud hodnota akcie v čase  $[0, T]$  klesne pod hodnotu  $a$ .

### 12.1 Binární bariérové opce

Uvažujme pro konkrétnost opci typu *up and in*.

Výplatní funkce nabývá pouze dvou hodnot.

$$V_T = 1 \left\{ \max_{t \in [0, T]} S_t \geq A \right\} = \begin{cases} 1 & \text{pokud } \max_{t \in [0, T]} S_t \geq A \\ 0 & \text{jinak.} \end{cases}$$

Převedením na Wienerův proces bez driftu (pomocí Cameron-Martinovy věty) a použitím principu reflexe, vypočteme pravděpodobnost, že  $\max W(t) \geq A$ , kde  $A$  je aktivující bariéra,  $S_t$  je cena akcie v čase  $t$ .

Předpoklady jsou jako u Black-Scholesova modelu pro evropskou call opci s konstantní úrokovou mírou. Máme dvě aktiva, bezrizikový dluhopis, jehož

cena v čase  $t$  je  $B_t$  a rizikovou akcií, jejíž cena v čase  $t$  je  $S_t$  a cena v čase 0 je  $S_0$ , což je známá hodnota.

Dluhopis má konstantní úrokovou míru  $r$ , tedy

$$\frac{dB_t}{dt} = rB_t \Rightarrow B_t = B_0 e^{rt}.$$

Při odvozování Black-Scholesova vzorce jsme dokázali že

$$S_t = S_0 \exp \left( \left( r - \frac{\sigma^2}{2} \right) t + \sigma W(t) \right)$$

vůči risk-neutrální míře  $P$ .

Pro jednoduchost předpokládejme, že  $S_0 = 1$  a  $\sigma = 1$ . Toho lze docílit vhodnou volbou jednotek času a peněz. Tedy

$$S_t = \exp \left( \left( r - \frac{1}{2} \right) t + W(t) \right).$$

Hodnota opce v čase  $t = 0$  je rovna diskontované očekávané hodnotě v čase  $T$  vůči míře  $P$ , tedy

$$\begin{aligned} V_0 &= e^{-rt} E_P(V_t) = e^{-rt} [0P(\max_{0 \leq t \leq T} S_t < A) + 1P(\max_{0 \leq t \leq T} S_t \geq A)] = \\ &= e^{-rt} P \left( \max_{0 \leq t \leq T} \left[ \exp \left( \left( r - \frac{1}{2} \right) t + W(t) \right) \right] \geq A \right) = \\ &= e^{-rt} P \left( \max_{0 \leq t \leq T} \left[ \left( r - \frac{1}{2} \right) t + W(t) \right] \geq \alpha \right), \end{aligned}$$

kde  $\alpha = \ln A$ . Označme

$$\widetilde{W}(t) = \left( r - \frac{1}{2} \right) t + W(t) = \gamma t + W(t)$$

Wienerův proces s driftem, kde  $\gamma = r - \frac{1}{2}$ . Pomocí Cameron-Martinovy věty najdeme pravděpodobnostní míru  $Q$ , vůči níž je  $\widetilde{W}(t)$  standardní Wienerův proces. Podle Cameron-Martinovy věty máme pro  $Q$ :

$$\frac{dP}{dQ} = \exp \left( \gamma W(T) + \frac{1}{2} \gamma^2 T \right).$$

Vůči  $Q$  je  $\widetilde{W}$  standardní Wienerův proces, tedy  $\widetilde{W}$  vůči  $Q$  se chová stejně jako  $W$  vůči  $P$ . Odtud dostáváme:

$$\begin{aligned} V_0 &= e^{-rt} P(\max_{0 \leq t \leq T} [\gamma t + W(t)] \geq \alpha) = \\ &= e^{-rt} E_P \left[ 1 \left\{ 0 \leq t \leq T \max \widetilde{W}(t) \geq \alpha \right\} \right] = \\ &= e^{-rt} E_Q \left[ \exp \left( \gamma W(T) + \frac{1}{2} \gamma^2 T \right) 1 \left\{ \max_{0 \leq t \leq T} \widetilde{W}(t) \geq \alpha \right\} \right] = \end{aligned}$$

$$\begin{aligned}
&= e^{-rt} E_Q \left[ \exp \left( \gamma \left( \widetilde{W}(T) - \gamma T \right) + \frac{1}{2} \gamma^2 T \right) 1 \left\{ \max_{0 \leq t \leq T} \widetilde{W}(t) \geq \alpha \right\} \right] = \\
&= e^{-rt} e^{-\frac{1}{2} \gamma^2 T} E_Q \left[ \exp \left( \gamma \widetilde{W}(T) \right) 1 \left\{ 0 \leq t \leq T \max \widetilde{W}(t) \geq \alpha \right\} \right] = \\
&= e^{-rt} e^{-\frac{1}{2} \gamma^2 T} E_P \left[ \exp \left( \gamma W(T) \right) 1 \left\{ \max_{0 \leq t \leq T} W(t) \geq \alpha \right\} \right].
\end{aligned}$$

Očekávání obsahuje pouze funkci standardního Wienerova procesu, můžeme tedy sestavit integrál popisující toto očekávání. Je-li  $\max_{0 \leq t \leq T} W(t) < \alpha$ , je očekávání nulové.

Zaměříme se tedy pouze na případ

$$\max_{0 \leq t \leq T} W(t) \geq \alpha.$$

Je-li  $W(T) \geq \alpha$ , pak

$$\max_{0 \leq t \leq T} W(t) \geq \alpha$$

s jistotou. Pravděpodobnostní rozdělení  $W(T)$  je  $N(0, T)$ , a tedy očekávání v tomto případě je rovno (substituce  $y = x - \alpha$ ,  $x = y + \alpha$ ,  $dx = dy$ )

$$\begin{aligned}
\frac{1}{\sqrt{2\pi T}} \int_{\alpha}^{\infty} e^{\gamma x} e^{-\frac{x^2}{2T}} dx &= \frac{1}{\sqrt{2\pi T}} \int_0^{\infty} e^{\gamma(y+\alpha)} e^{-\frac{(y+\alpha)^2}{2T}} dy = \\
&= \frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int_0^{\infty} e^{\gamma y} e^{-\frac{(y+\alpha)^2}{2T}} dy.
\end{aligned}$$

Ve druhém případě, pokud  $W(t) < \alpha$ , víme z principu reflexe, že pokud

$$\max_{0 \leq t \leq T} W(t) \geq \alpha,$$

pak  $W(T)$  má symetrické rozdělení okolo  $\alpha$ . Tedy, je-li  $p(x)$  hustota  $W(T)$ , pak platí

$$p(x) = p(2\alpha - x)$$

pro každé  $x$ . Tedy pokud  $W(t) < \alpha$ , má  $e^{\gamma W(T)}$  očekávání (substituce  $y = x - \alpha$ ,  $x = y + \alpha$ ,  $dx = dy$ )

$$\begin{aligned}
\frac{1}{\sqrt{2\pi T}} \int_{-\infty}^{\alpha} e^{\gamma x} e^{-\frac{(2\alpha-x)^2}{2T}} dx &= \frac{1}{\sqrt{2\pi T}} \int_{-\infty}^0 e^{\gamma(y+\alpha)} e^{-\frac{(-y+\alpha)^2}{2T}} dy = \\
&= \frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int_{-\infty}^0 e^{\gamma y} e^{-\frac{(-y+\alpha)^2}{2T}} dy = \frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int_0^{\infty} e^{-\gamma z} e^{-\frac{(z+\alpha)^2}{2T}} dz.
\end{aligned}$$

Celkem tedy máme:

$$\begin{aligned}
E_P \left[ e^{\gamma W(T)} 1 \left\{ \max_{0 \leq t \leq T} W(t) \geq \alpha \right\} \right] &= \\
&= \frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int (e^{-\gamma x} + e^{\gamma x}) e^{-\frac{(x+\alpha)^2}{2T}} dx.
\end{aligned}$$

Doplněním na čtverec dostaneme:

$$\begin{aligned} & \frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int_0^\infty (e^{-\gamma x} + e^{\gamma x}) e^{-\frac{(x+\alpha)^2}{2T}} dx = \\ & = e^{\gamma\alpha} e^{\frac{\gamma^2 T}{2}} \left[ e^{\gamma\alpha} \phi\left(\frac{-\gamma T - \alpha}{\sqrt{T}}\right) + e^{-\gamma\alpha} \phi\left(\frac{\gamma T - \alpha}{\sqrt{T}}\right) \right], \end{aligned}$$

kde  $\phi$  je distribuční funkce standardního normálního rozdělení  $N(0, 1)$ . Dále,

$$\frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int_0^\infty (e^{-\gamma x} + e^{\gamma x}) e^{-\frac{(x+\alpha)^2}{2T}} dx$$

Nejprve doplníme na čtverec exponent prvního integrálu po roznásobení:

$$\begin{aligned} -\gamma x - \frac{(x+\alpha)^2}{2T} &= \frac{-2T\gamma x - (x^2 + 2x\alpha + \alpha^2)}{2T} = \\ &= -\frac{x^2 + (2\alpha + 2T\gamma)x + \alpha^2}{2T} = -\frac{(x + \alpha + T\gamma)^2 - 2\alpha T\gamma - T\gamma^2}{2T} \end{aligned}$$

Dostáváme tedy

$$\begin{aligned} \frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int_0^\infty e^{-\frac{(x+\alpha+T\gamma)^2}{2T}} e^{\alpha\gamma} e^{\frac{T\gamma^2}{2}} dx &= \frac{1}{\sqrt{2\pi T}} e^{2\gamma\alpha} e^{\frac{T\gamma^2}{2}} \int_0^\infty e^{-\frac{(x+\alpha+T\gamma)^2}{2T}} dx = \\ &= e^{2\gamma\alpha} e^{\frac{T\gamma^2}{2}} P(Z_1 \geq 0), \end{aligned}$$

kde  $Z_1 \sim N(-\alpha - T\gamma; T)$ . Dále,

$$\begin{aligned} P(Z_1 \geq 0) &= P\left(\frac{Z_1 + \alpha + T\gamma}{\sqrt{T}} \geq \frac{\alpha + T\gamma}{\sqrt{T}}\right) = \\ &= 1 - \phi\left(\frac{\alpha + T\gamma}{\sqrt{T}}\right) = \phi\left(\frac{-\alpha - T\gamma}{\sqrt{T}}\right) \end{aligned}$$

Celkem

$$e^{2\gamma\alpha} e^{\frac{T\gamma^2}{2}} \phi\left(\frac{-\alpha - T\gamma}{\sqrt{T}}\right).$$

Analogicky postupujeme pro druhý integrál. Nejprve doplníme na čtverec exponent druhého integrálu:

$$\begin{aligned} \gamma x - \frac{(x+\alpha)^2}{2T} &= \frac{2T\gamma x - (x^2 + 2x\alpha + \alpha^2)}{2T} = \\ &= -\frac{x^2 + (2\alpha - 2T\gamma)x + \alpha^2}{2T} = -\frac{(x + \alpha - T\gamma)^2 + 2\alpha T\gamma - T\gamma^2}{2T}. \end{aligned}$$



Dostáváme tedy

$$\begin{aligned} & \frac{1}{\sqrt{2\pi T}} e^{\gamma\alpha} \int_0^\infty e^{-\frac{(x+\alpha-T\gamma)^2}{2T}} e^{-\alpha\gamma} e^{\frac{T\gamma^2}{2}} dx = \\ & = \frac{1}{\sqrt{2\pi T}} e^{\frac{T\gamma^2}{2}} \int_0^\infty e^{-\frac{(x+\alpha-T\gamma)^2}{2T}} dx = e^{\frac{T\gamma^2}{2}} P(Z_2 \geq 0), \end{aligned}$$

kde  $Z_2 \sim N(-\alpha + T\gamma; T)$ . Dále,

$$\begin{aligned} P(Z_2 \geq 0) &= P\left(\frac{Z_2 + \alpha - T\gamma}{\sqrt{T}} \geq \frac{\alpha - T\gamma}{\sqrt{T}}\right) = \\ &= 1 - \Phi\left(\frac{\alpha - T\gamma}{\sqrt{T}}\right) = \Phi\left(\frac{-\alpha + T\gamma}{\sqrt{T}}\right) \end{aligned}$$

Celkem dostaneme

$$e^{\frac{T\gamma^2}{2}} \Phi\left(\frac{T\gamma - \alpha}{\sqrt{T}}\right).$$

Tedy

$$\begin{aligned} & e^{\frac{T\gamma^2}{2}} \left[ e^{2\gamma\alpha} \Phi\left(\frac{-\alpha - T\gamma}{\sqrt{T}}\right) + \Phi\left(\frac{T\gamma - \alpha}{\sqrt{T}}\right) \right] = \\ & e^{\frac{T\gamma^2}{2}} e^{\alpha\gamma} \left[ e^{\gamma\alpha} \Phi\left(\frac{-\alpha - T\gamma}{\sqrt{T}}\right) + e^{-\gamma\alpha} \Phi\left(\frac{T\gamma - \alpha}{\sqrt{T}}\right) \right] \end{aligned}$$

Tedy hodnota opce v čase  $t = 0$  je rovna

$$V_0 = e^{-rt} P(\max_{0 \leq t \leq T} S_t \geq A) = e^{-rt} e^{\gamma\alpha} \left[ e^{\gamma\alpha} \Phi\left(\frac{-\gamma T - \alpha}{\sqrt{T}}\right) + e^{-\gamma\alpha} \Phi\left(\frac{\gamma T - \alpha}{\sqrt{T}}\right) \right].$$