

Stochastická analýza

Doc. RNDr. Martin Kolář, Ph.D.



Obsah

1	Spojité náhodné veličiny a stochastické procesy	4
1.1	Stochastické procesy	4
1.2	Spojité náhodné veličiny	5
1.2.1	Nezávislost a její charakterizace	6
1.2.2	Příklady spojitých rozdělení	8
2	Charakteristická funkce a její vlastnosti	10
2.1	Charakteristická funkce	10
2.2	Základní vlastnosti Fourierovy transformace	12
2.3	Základy L^2 -teorie	17
2.4	Borel-Cantelliho lemma	19
3	Wienerův proces	21
3.1	Definice Wienerova procesu	21
3.2	Ciesielskiho konstrukce	21
4	Lineární a kvadratická variace	28
4.1	Lineární variace	28
4.2	Kvadratická variace	29
5	Itôův integrál a Itôovo lemma	33
5.1	Itôův integrál	33
5.2	Itôovo lemma	38
6	Martingaly a Itôovy procesy	42
6.1	Martingal (= férová hra)	42
6.2	Itôův proces a stopping time	43
7	Black-Scholesův model	46
7.1	Odvození Black-Scholesova vzorce pro evropskou call opci	48

8	Oceňování bariérových opcí	51
8.1	Radon-Nikodýmova derivace	51
8.2	Cameron-Martinova věta	52
8.3	Bariérové opce	55
8.4	Binární bariérové opce	55
9	Rovnice vedení tepla a Wienerův proces	60
9.1	Řešení rovnice vedení tepla na přímce	60
9.2	Souvislost řešení rovnice vedení tepla a Wienerova procesu . .	61
9.3	Feynman-Kacova formule	62

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 (Ω, \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

Všechny uvedené příklady se probírají v přednáškách MF001 a MF002, s výjimkou Poissonova procesu. Uveďme si tedy pro úplnost příklad Poissonova procesu:

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 λ 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 (Ω, \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

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

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

a 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 nezávislé jevy $\{X \leq x\}$ a $\{Y \leq y\}$.

Základní charakteristikou náhodné veličiny je její očekávání.

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

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

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

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

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 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

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

Definice 1.2.7. Náhodné veličiny X a Y mají *sdruženou 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 definovány jako:

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

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*

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

1.2.2 Příklady spojitých rozdělení

Uniformní (stejněměrné) 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 μ je střední hodnota a σ^2 je rozptyl.

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

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

Hodnota normalizační konstanty plyne z hodnoty tzv. Laplaceova integrálu:

Lemma 1.2.10. *Platí*

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

Důkaz: Označme

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

Uvažujme druhou mocninu tohoto integrálu

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

Provedeme transformaci do polárních souřadnic. Máme

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

protože

$$\int_0^{\infty} r \cdot e^{-\frac{r^2}{2}} dr = \left| \begin{array}{l} -\frac{r^2}{2} = t \\ -\frac{2r}{2} dr = dt \end{array} \right| = \int_0^{-\infty} -e^t dt = \int_{-\infty}^0 e^t dt = [e^t]_{-\infty}^0 = 1 - (e^{-\infty}) = 1.$$

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 ρ 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. *Jsou-li normálně rozdělené náhodné veličiny X a Y nekorelované, t.j. $\rho = 0$, pak jsou nezávislé.*

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

Kapitola 2

Charakteristická funkce a její vlastnosti

2.1 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 veličiny).

Definice 2.1.1. *Moment generující funkce* náhodné veličiny X je definována jako

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

pro $t \geq 0$.

Tedy je-li X spojitá náhodná veličina s hustotou f , pak

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

Až na obor integrace 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

Lemma 2.1.2. *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.

Definice 2.1.3. *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.

2.2 Základní vlastnosti Fourierovy transformace

Definice 2.2.1. *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 dán vztahem

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

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 2.2.2. *(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 2.2.3. *(O Fourierově transformaci derivace).* Necht' $f \in L^1 \cap C$, $f' \in L^1 \cap C$ a $\lim_{x \rightarrow \pm\infty} f(x) = 0$. Pak

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

Tedy derivování se Fourierovou transformací převádí na násobení.

Důkaz: Integrovaním 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 2.2.4. (*O derivaci Fourierovy transformace*) Necht' $f \in L^1 \cap C$ 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 ξ dostaneme

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

Konvoluce: 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 2.2.5. (*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 2.2.6. (O transformaci posunutí a o posunutí transformace) Nechť $f \in L^1 \cap C$. Pro $a > 0$ označme $f_a(x) = f(x-a)$. Pak

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

Naopak,

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

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,

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

Důsledek 2.2.7. Nechť 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, ω 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 2.2.8. (*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

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

Na jedné straně je

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

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

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

Celkem F splňuje rovnici

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

Separací proměnných dostaneme řešení

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

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 2.2.9. Označme jako $H(x)$ Heavisideovu funkci, t.j. $H(x) = 1$ 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

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

Věta 2.2.10. (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

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

Věta 2.2.11. (O inverzní transformaci) Nechť $f \in L^1 \cap C$, f je stejnoměrně spojitá a $\hat{f} \in L^1 \cap C$. Pak $\hat{\hat{f}}(t)$ lze vypočítat z $f(x)$ vztahem

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

Důsledek 2.2.12. Charakteristická funkce jednoznačně určuje hustotu náhodné veličiny.

2.3 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 2.3.1. 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 2.3.2. Necht' $\{\phi_k\}_{k=0}^{\infty}$ je ortonormální systém. Čísla

$$c_k = \int_a^b f(x) \overline{\phi_k(x)} dx$$

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 . Konvergenci 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 2.3.3. *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 $j = 0, \dots, N$.

Lemma 2.3.4. *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 je to Pythagorova věta.)

Pro dvě funkce máme Parsevalovu rovnost:

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

kde pruh značí komplexně sdružené číslo.

Lemma 2.3.5. *Fourierova řada konverguje pro každou funkci $f \in L^2([a, b])$ právě tehdy, když systém $\{\phi_k\}_{k=0}^\infty$ je úplný.*

2.4 Borel-Cantelliho lemma

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

Lemma 2.4.1. (Borel-Cantelli) *Nechť (Ω, \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*

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

tj.

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

Pak platí:

Jestliže

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

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

Jestliže

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

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

Důkaz: Platí

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

pro $\forall n$. 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

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

Kapitola 3

Wienerův proces

3.1 Definice Wienerova procesu

Definice 3.1.1. Reálný stochastický proces $W(t)$ na pravděpodobnostním prostoru (Ω, \mathcal{A}, P) se nazývá (standardní) **Wienerův proces** (neboli **Brownův pohyb**), jestliže platí:

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

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

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

3.2 Ciesielskiho konstrukce

Definice 3.2.1. Pro $t \in [0, 1]$ definujeme **Haarovy funkce** $\{h_k(t)\}_{k=0}^{\infty}$ takto. 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

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

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

Například pro $n = 73$ máme

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

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 $k = 19$.

Připomeňme v této souvislosti pojem **nosič funkce**:

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

Například,

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

Věta 3.2.2. Funkce $\{h_k\}_{k=0}^{\infty}$ tvoří úplný, ortonormální systém v prostoru $L^2([0, 1])$.

Důkaz: Začneme s důkazem ortogonálnosti, t.j.

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

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 nosič h_m leží v intervalu, kde h_n je konstantní, tedy

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

Dále ukážeme, že $\langle h_n, h_n \rangle = 1$, tedy ortonomalitu 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

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

Po substituci $u = 2^j t - k$, $du = 2^j dt$ 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 $\{\varphi_n\}_1^\infty$, která konverguje k f . Opravdu, z Haarových funkcí jako lineární kombinace dostaneme funkce po částech konstantní na dyadických intervalech v $[0, 1]$, 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 3.2.3. Pro $n = 1, 2, \dots$ definujeme n -tou **Schauderovu funkci** vztahem

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

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

Poznámka. Grafem n -té Schauderovy funkce je rovnoramenný trojúhelník, jehož výška je $\frac{1}{2^{j+1}} 2^{\frac{j}{2}} = 2^{\frac{j}{2}-j-1} = 2^{-\frac{j}{2}-1}$. **Lemma 3.2.4.** Necht' $\{a_k\}_{k=1}^\infty$ 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 3.2.5. *Nechť $\{A_k\}_{k=1}^{\infty}$ jsou nezávislé náhodné veličiny na pravděpodobnostním prostoru (Ω, \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

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

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

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

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

Věta 3.2.6. *Nechť $W(t)$ je Wienerův proces. Pak*

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

Důkaz: Necht' $s \geq t \geq 0$. 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 přírůstky $W(s) - W(t)$ jsou nezávislé, $E(W^2(t)) = t$ z definice a

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

z nezávislosti. ■

Věta 3.2.7. 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 skalární součin 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

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

Tedy celkem $\min(s, t) = s = \sum_0^{\infty} s_k(t) s_k(s)$. ■

Věta 3.2.8. (Ciesielskiho konstrukce Wienerova procesu): Necht' $\{A_k\}_{k=1}^{\infty}$ 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 ω , a $W(t)$ je Wienerův proces.

Důkaz: Stejnoměrná konvergence plyne z předchozích lemmat. Ze stejnoměrné 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 vlastnosti

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

máme

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

a podle pomocného tvrzení

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

máme

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

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 podle definice

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

$$E \left[\left(\sum_{k=1}^{\infty} A_k (\omega) s_k (t) \right) \left(\sum_{k=1}^{\infty} A_k (\omega) s_k (s) \right) \right] =$$

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

protože z nezávislosti máme

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

pro $k \neq l$.

Tedy

$$E \left(\sum_{k=1}^{\infty} [A_k^2 (\omega)] s_k (t) s_k (s) \right) =$$

$$= \sum_{k=1}^{\infty} E [A_k^2 (\omega)] s_k (t) s_k (s) = \sum_{k=1}^{\infty} s_k (t) s_k (s) = \min (t, s) = 1,$$

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

Máme

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

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

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

Tedy přírůstky jsou nekorelované a tedy nezávislé. ■

Kapitola 4

Lineární a kvadratická variace

4.1 Lineární variace

Variace je míra proměnlivosti (variability) funkce na daném intervalu. Nechť $f : [a, b] \rightarrow \mathbb{R}$ je spojitá funkce a nechť $D = \{a = t_1 < t_2 < \dots < t_n = b\}$ 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 4.1.1. *lineární variaci funkce f* je definována jako

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

kde $\|D\|$ je norma dělení, tj.

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

Příklad 4.1.2. Funkce $f(x) = x^2$ na intervalu $[0, 1]$ má lineární variaci

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

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

$$\begin{aligned} LV(f, D) &= \sum_{j=1}^{n-1} (f(t_{j+1}) - f(t_j)) = \\ &= f(t_n) - f(t_1) = f(b) - f(a) = f(1) - f(0). \end{aligned}$$

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

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

Příklad 4.1.3. Vypočtete 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 funkce s grafem nabývajícím 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, neboť $LV = \infty$ pro skoro všechny trajektorie.

4.2 Kvadratická variace

Definice 4.2.1. Nechť $D = \{t_1, \dots, t_n\}$ je dělení intervalu $[0, T]$, tedy $0 = t_1 < t_2 < \dots < t_n = T$. Pak **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 4.2.2. *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 $\int_0^T (f'(t))^2 dt$ je konečný. ■

Lemma 4.2.3. *Nechť $W(t)$ je Wienerův proces. Pak*

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

Důkaz: Máme $W(t) - W(s) \sim N(0, t - s)$. Speciálně pro $s = 0$ je $W(t) \sim N(0, t)$, tedy $E(W(t)) = 0$ a $E(W^2(t)) = t$. $N(0, t)$ 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

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

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

Věta 4.2.4. *Nechť $W(t)$ je Wienerův proces na intervalu $[0, T]$ a necht' $D = \{0 = t_1 < t_2 < \dots < t_n = T\}$ 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 $\Delta t_k \rightarrow 0$ (tj. konvergence 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 rovnu T (všechny stejnou).

Důsledek 4.2.5. Trajektorie Wienerova procesu mají nekonečnou lineární variaci.

Důsledek 4.2.6. 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 5

Itôův integrál a Itôovo lemma

5.1 Itôův integrál

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

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

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 podobný integrál, kde ale f není hladká funkce, konkrétně

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

kde W_t je Wienerův proces.

Tyto integrály se liší se 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 5.1.1. (motivační) Nechť $W_t(\omega)$ je cena akcie v čase t při tržním scénáři ω . Nechť $f(t, \omega)$ je obchodní strategie, tj. počet držených akcií v čase t za scénáře ω . Pak

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

je zisk ze strategie v časovém intervalu $[t, t + 1]$.

Součtem těchto zisků dostaneme $\int_a^b f \cdot dW$ který představuje zisk ze strategie v časovém intervalu $[a, b]$.

Příklad 5.1.2. (závislost na volbě vnitřního bodu): Mějme dělení intervalu $[0, T]$, $D = \{0 = t_0 < t_1 < \dots < t_n = T\}$ a

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

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

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

Poslední člen je tzv. teleskopující součet a rovná se

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

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

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

Speciálně:

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

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

Ve financích se používá jen Itôův integrál, protože portfolio musíme sestavit před pohybem ceny (viz. dále).

Definice 5.1.3. Systém σ -algeber $\mathcal{F} = \{\mathcal{F}_t, t \in \tau\}$ na pravděpodobnostním prostoru (Ω, \mathcal{A}, P) se nazývá **filtrace**, pokud pro všechna $t \in \tau$ je $\mathcal{F}_t \subseteq \mathcal{A}$, kde \mathcal{A} jsou pozorovatelné jevy a $\mathcal{F}_s \subseteq \mathcal{F}_t$ pro $s < t$, kde $s, t \in \tau$.

Definice 5.1.4. Nechť $W(t)$ je Wienerův proces na (Ω, \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 σ -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 5.1.5. \mathcal{F}_t je nejmenší σ -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 (libovolné časy) a $F_j \subseteq \mathbb{R}$ jsou libovolné Borelovské množiny.

Věta 5.1.6. 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

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

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 5.1.7. Nechť $W(t)$ je Wienerův proces na prostoru (Ω, \mathcal{A}, P) a nechť \mathcal{F} je historie Wienerova prostoru. Říkáme, že proces $\{G(t, \omega); t \in [0, \infty)\}$ je **adaptovaný historii Wienerova procesu** (neboli $G(t, \omega)$ je **neanti-cipativní**¹), 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 σ -algebami \mathcal{F}_t .

¹tj. nepředvídá budoucnost

Definice 5.1.8. 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 5.1.9. Nechť S je jednoduchá funkce. Pak

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

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

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

Definice 5.1.10. Nechť $W(t)$ je Wienerův proces na prostoru (Ω, \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 5.1.11. (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)

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

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 ω). Φ je jednoduchá funkce. Integrál

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

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

Věta 5.1.12. (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

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

■

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

Lemma 5.1.13. *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*

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

(konvergence v pravděpodobnosti).

Definice 5.1.14. 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 5.1.15. (*Základní vlastnosti Itôova integrálu*) Platí

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

Důkaz: První tvrzení plyne ihned z definice. Dokážeme druhé tvrzení. G je jednoduchá funkce $G(t, \omega) = G_k(\omega)$ 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:

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

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

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

■

5.2 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

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

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 5.2.1. Nechť W_t je Wienerův proces na pravděpodobnostním prostoru (Ω, \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 a $\int_0^t v(s, \omega) dW_s(\omega)$ je stochastický člen.

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 $u(t, \omega)$ je drift a $v(t, \omega)$ je volatilita.

Věta 5.2.2. *Nechť $X(t, \omega)$ je Itôův proces se stochastickým diferenciálem*

$$dX(t) = U dt + V dW(t),$$

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

$$(dX(t))^2 = (U dt + V dW(t))^2 = (dX(t))(dX(t))$$

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

Příklad 5.2.3. (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

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

má lognormální rozdělení.

Kapitola 6

Martingaly a Itôovy proces

6.1 Martingal (= férová hra)

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

$$E(S_{n+1} | X_0, X_1, \dots, X_n) = S_n,$$

se nazývá martingal vzhledem k posloupnosti X_n .

Definice 6.1.1. *Filtrace* na (Ω, \mathcal{A}, P) je systém σ -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 $s \leq t$.

Definice 6.1.2. *Historie Wienerova procesu* je σ -algebra generovaná náhodnými veličinami $W(s)$ pro $s \leq t$. Popisuje růst informace o trajektorii Wienerova procesu v závislosti na čase.

Definice 6.1.3. Necht' $\{M_t; t \geq 0\}$ je stochastický proces na pravděpodobnostním prostoru (Ω, \mathcal{A}, P) a $\{\mathcal{F}_t, t \geq 0\}$ je historie Wienerova procesu. M_t se nazývá **martingal** vzhledem k \mathcal{F}_t , 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

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

pro všechna $s \geq t$, tzv. *Martingalová podmínka*.

Řečeno slovy: "Očekávání budoucí hodnoty je rovno současné hodnotě."

Věta 6.1.4. Necht' $\{W(t); t \geq 0\}$ je Wienerův proces na pravděpodobnostním prostoru (Ω, \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

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

Jelikož jsou obě funkce v integrálu sudé, můžeme psát

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

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

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

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 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.

6.2 Itôův proces a stopping time

Definice 6.2.1. Nechť $W(t)$ je standardní Wienerův proces na (Ω, \mathcal{A}, P) a $\{\mathcal{F}_t\}$ je historie Wienerova procesu. Nezáporná náhodná veličina τ se nazývá **stopping time** ("čas zastavení"), jestliže pro všechna $t \geq 0$ je událost (jev)

$\{\tau \leq t\}$ prvkem σ -algebry \mathcal{F}_t .

V čase t tedy víme, zda čas τ už nastal, nebo ne.

Příklad 6.2.2. 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 τ_a je stopping time.

Příklad 6.2.3. 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 τ nastal nebo ne (může být potom ještě vyšší hodnota), tedy nejde o stopping time.

Věta 6.2.4. (*Princip reflexe*): Nechť $W(t)$ je Wienerův proces, $a > 0$ a $\tau(a)$ je čas prvního dosažení bodu a . Platí

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

Výraz na pravé straně rovnice umíme spočítat:

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

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

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

Celkem

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

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

Kapitola 7

Black-Scholesův model

Předpoklady Black-Scholesova modelu:

Na trhu existují dvě aktiva,

- bezrizikový dluhopis, kde B_t je cena v čase t ,
- riziková akcie, kde S_t je cena v čase t a S_0 je cena v čase 0, což je 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

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

Řešením (separací proměnných) dostaneme:

$$\frac{dB_t}{B_t} = r_t \cdot dt,$$

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

$$dS_t = \mu_t \cdot S_t \cdot dt + \sigma \cdot S_t \cdot dW_t \quad (7.1)$$

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

Věta 7.0.5. (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, tj.

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

kde S_t^* je diskontovaná cena v čase t .

Věta 7.0.6. Necht koeficient driftu μ_t je omezený, pak stochastická diferenciální rovnice (7.1) má řešení

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

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

Důkaz: Použijeme Itôovu formuli na funkci

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

Pro $S = g(X, t)$, kde $X = W$, dostaneme

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

tedy S řeší rovnici (7.1).

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

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

Tedy S_t^* je martingal právě tehdy, když koeficient u dt je $\equiv 0$, tedy $r_t = \mu_t$ pro všechna t . ■

Důsledek 7.0.7. Vzhledem k rovnovážné pravděpodobnostní míře ($r_t = \mu_t$) 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 $\sigma^2 t$.

7.1 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 cena opce V_0 .

Podle základní věty arbitrážní oceňovací 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 .

Tedy podle předchozí věty

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

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.

Výpočtem očekávání (příslušného integrálu - viz dále) dostaneme Black-Scholesův vzorec

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

kde

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

a ϕ je distribuční funkce normálního rozdělení:

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

Nechť V_0 je cena opce v čase $t = 0$. Podle základní věty arbitrážní teorie víme, že $V_0 =$ diskontované očekávání hodnoty V_T v čase T vůči risk-neutrální míře, tedy

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

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

Tedy

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

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

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

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

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

V prvním integrálu doplníme v exponentu na čtverec:

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

a dostáváme:

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

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

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

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

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

což už je Black-Scholesův vzorec.

Kapitola 8

Oceňování bariérových opcí

8.1 Radon-Nikodýmova derivace

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

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

Označíme

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

Wienerův proces s driftem. Chceme najít pravděpodobnostní míru Q na Ω tak, aby $\widetilde{W}(t)$ byl obyčejný Wienerův proces na pravděpodobnostním prostoru (Ω, \mathcal{A}, Q) .

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

Definice 8.1.1. Nechť (Ω, \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 (Ω, \mathcal{A}) a pro náhodnou veličinu $Z = \frac{dQ}{dP}$ platí

$$\begin{aligned} E_Q(X) &= \Omega \int X \cdot dQ = \Omega \int X \cdot \frac{dQ}{dP} \cdot dP = \\ &= \Omega \int X \cdot Z \cdot dP = E_P(X \cdot Z) = E_P \left[\frac{dQ}{dP} X \right], \end{aligned}$$

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

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

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

K důkazu je třeba moment generující funkce.

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

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

kde f je hustota X .

Lemma 8.2.3. Necht X je náhodná veličina s rozdělením

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

a θ je parametr. Pak

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

Důkaz:

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

Doplníme na čtverec v exponentu:

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

protože

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

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

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

Musíme dokázat vlastnosti Wienerova procesu vzhledem ke Q . Máme

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

Spojitost trajektorií plyne ze spojitosti trajektorií $W(t)$ a spojitosti γt .

Nyní s využitím přechodního lemmatu dokážeme, že $\widetilde{W}(t)$ má vůči Q rozdělení $N(0, t)$. Moment generující funkce určuje jednoznačně pravděpodobnostní rozdělení.

Vypočteme moment generující funkce \widetilde{W} vůči Q :

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

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

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

Podle předchozího lemmatu $\sigma^2 = t$ respektive $\sigma^2 = T - t$, tedy předchozí výraz je roven

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

neboť

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

což dává moment generující funkci $N(0, t)$. Zcela analogicky se dokáže, že

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

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

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

Věta 8.2.4. (Girsanov): *Nechť $W(t, \omega)$, $0 \leq t \leq T$ je Wienerův proces na (Ω, \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 (Ω, \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 8.2.5. (obrácená Girsanovova věta): *Nechť $W(t, \omega)$, $0 \leq t \leq T$ je Wienerův proces na (Ω, \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 (Ω, \mathcal{A}, Q) . Navíc

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

8.3 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 .

8.4 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 akci, 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

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

Při odvozování Black-Scholesova vzorce jsme dokázali že

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

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

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

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 :

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

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

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

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 $y = x - \alpha$, $x = y + \alpha$, $dx = dy$)

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

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 α . 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 $y = x - \alpha$, $x = y + \alpha$, $dx = dy$)

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

Celkem tedy máme:

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

Doplněním na čtverec dostaneme:

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

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

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

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

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

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

$$P(Z_1 \geq 0) = P\left(\frac{Z_1 + \alpha + T\gamma}{\sqrt{T}} \geq \frac{\alpha + T\gamma}{\sqrt{T}}\right) = 1 - \Phi\left(\frac{\alpha + T\gamma}{\sqrt{T}}\right) = \Phi\left(\frac{-\alpha - T\gamma}{\sqrt{T}}\right)$$

Celkem

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

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

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

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

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

Celkem dostaneme

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

Tedy

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

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

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

■

Kapitola 9

Rovnice vedení tepla a Wienerův proces

9.1 Řešení rovnice vedení tepla na přímce

Chceme řešit rovnici vedení tepla na přímce, t.j.

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

pro $x \in \mathbb{R}$ a $t \geq 0$. $u(x, t)$ je teplota v bodě x a čase t . Teplota v počátečním čase je známa, 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 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 ξ je to obyčejná diferenciální rovnice v proměnné t , kterou umíme vyřešit,

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

kde $C = \hat{u}(\xi, 0)$, 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 $R = \sqrt{4\pi t}$. Tak dostaneme tzv. Gaussovo jádro

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

Řešení počáteční úlohy pro rovnici vedení tepla má tedy tvar

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

9.2 Souvislost řešení rovnice vedení tepla a Wienerova procesu

Z definice Wienerova procesu víme, že

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

Tato funkce je zároveň Gaussovo jádro.

Věta 9.2.1. *Nechť $f : \mathbb{R} \rightarrow \mathbb{R}$ je omezená funkce. Pak jednoznačné řešení $u(t, x)$ počáteční úlohy pro rovnici vedení tepla:*

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

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

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

je počáteční podmínka, je rovno

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

kde $P_t(x, y)$ je Gaussovo jádro:

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

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 .

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

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

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

Tedy

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

■

9.3 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).

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

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

tedy zpětnou rovnici vedení tepla s koncovou podmínkou

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

kde μ, σ, ψ jsou dané funkce a T je pevně daný čas, $T > 0$.

Věta 9.3.1. (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: Necht 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 předpokladu $X_t = x$). 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

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

■