

# Rachunek prawdopodobieństwa i statystyka

Wykład 6

# Funkcja generująca moment

**Definicja:** Funkcją generującą moment (fgm) dla zmiennej losowej  $X$  nazywamy funkcję zmiennej rzeczywistej  $t$  postaci:

$$m_X(t) = \mathcal{E}[e^{tX}]$$

**Uwaga:** mgf istnieje zawsze dla  $t = 0$ . Jeśli  $X$  jest dodatnią zmienną losową oraz istnieje fgm dla określonej wartości  $t_0$  to wtedy fgm istnieje także dla  $t \leq t_0$

**Przykład:** fgm dla rozkładu dwumianowego

$$m_X(t) = \sum_{k=0}^n e^{tk} \binom{n}{k} p^k (1-p)^{n-k} = (pe^t + 1 - p)^n$$

**Przykład:** fgm dla rozkładu wykładniczego

$$m_X(t) = \int_0^{\infty} e^{tx} \lambda e^{-\lambda x} dx = \lambda \int_0^{\infty} e^{-(\lambda-t)x} dx = \frac{\lambda}{\lambda - t}$$

**Twierdzenie:** Jeśli spełniony jest warunek  $\mathcal{E}[|X|^n] < \infty$  to wówczas dla  $k$ -ty moment ( $k = 1, 2, \dots, n$ ) zmiennej losowej  $X$  dany jest przez:

$$m_k = \left. \frac{d^k}{dt^k} m_X(t) \right|_{t=0}$$

# Funkcja generująca moment

Przykład: fgm dla rozkładu dwumianowego

$$m_X(t) = (pe^t + 1 - p)^n$$

$$m_X'(t) = n(pe^t + 1 - p)^{n-1} pe^t \Rightarrow \mathcal{E}[X] = m_X'(0) = np$$

$$m_X''(t) = n(n-1)(pe^t + 1 - p)^{n-2} (pe^t)^2 + n(e^t + 1 - p)^{n-1} pe^t \Rightarrow \\ \Rightarrow \mathcal{E}[X^2] = m_X''(0) = n(n-1)p^2 + np$$

Twierdzenie: Jeśli  $m_X(t)$  jest fgm zmiennej  $X$ , to fgm zmiennej  $Y = \alpha X + \beta$  dane jest przez

$$m_Y(t) = e^{\beta t} m_X(\alpha t)$$

D:  $m_Y(t) = \mathcal{E}[e^{tY}] = \mathcal{E}[e^{t(\alpha X + \beta)}] = \mathcal{E}[e^{t\alpha X} e^{\beta t}] = e^{\beta t} m_X(\alpha t)$

Twierdzenie: Jeśli  $X$  i  $Y$  są statystycznie niezależnymi zmiennymi losowymi o fgm odpowiednio  $m_X(t)$  i  $m_Y(t)$  to fgm zmiennej  $X + Y$  dana jest przez

$$m_{X+Y}(t) = m_X(t) m_Y(t)$$

# Funkcja charakterystyczna

**Definicja:** Funkcją charakterystyczną zmiennej losowej  $X$  nazywamy funkcję zmiennej rzeczywistej  $t$  postaci:

$$\varphi_X(t) = \mathcal{E}[e^{itX}]$$

**Uwaga:** Funkcja charakterystyczna jest funkcją rzeczywistą wtedy i tylko wtedy gdy rozkład zmiennej losowej  $X$  jest symetryczny względem  $x = 0$

**Przykład:** Funkcja charakterystyczna dla rozkładu dwumianowego

$$\varphi_X(t) = \sum_{k=0}^n e^{itk} \binom{n}{k} p^k (1-p)^{n-k} = (pe^{it} + 1-p)^n$$

**Przykład:** Funkcja charakterystyczna dla rozkładu wykładniczego

$$\varphi_X(t) = \int_0^{\infty} e^{itx} \lambda e^{-\lambda x} dx = \lambda \int_0^{\infty} e^{-(\lambda-it)x} dx = \frac{\lambda}{\lambda - it}$$

**Twierdzenie:** Jeśli spełniony jest warunek  $\int_{-\infty}^{+\infty} |\varphi(t)| dt < \infty$  to wówczas mamy:

$$f(x) = F'(x) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} e^{-itx} \varphi(t) dt$$

$$p_k = \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-itk} \varphi(t) dt$$

# Funkcje charakterystyczne

**Przykład:** Znajdź gęstość p-twa zmiennej losowej  $X$ , której funkcja charakterystyczna dana jest przez

$$\varphi(t) = \exp(2it - 3|t|)$$

Sprawdzamy czy funkcja charakterystyczna jest całkowalna:

$$\int_{-\infty}^{+\infty} |\varphi(t)| dt = \int_{-\infty}^{+\infty} e^{-3|t|} dt = 2 \int_0^{\infty} e^{-3t} dt = \frac{2}{3} < \infty$$

Znajdujemy funkcję gęstości p-twa:  $f(x) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \exp(-itx + 2it - 3|t|) dt = \frac{1}{\pi} \frac{3}{(x-2)^2 + 9}$

**Przykład:** Wyznacz rozkład p-twa, którego funkcja charakterystyczna ma postać

$$\varphi(t) = \exp(2it)$$

Sprawdzamy czy funkcja charakterystyczna jest całkowalna:  $\int_{-\infty}^{+\infty} |\varphi(t)| dt = \int_{-\infty}^{+\infty} dt = \infty$

Ponieważ funkcja charakterystyczna jest okresowa ( $2\pi$ ) więc mamy do czynienia ze zmienną dyskretną:

$$p_k = \frac{1}{2\pi} \int_{-\pi}^{\pi} e^{-ik+2it} dt = \frac{1}{2\pi} \int_{-\pi}^{\pi} (\cos(2-k)t + i \sin(2-k)t) dt = \frac{1}{\pi} \frac{\sin(2-k)t}{2-k} \Big|_0^{\pi} = \begin{cases} 0 & \text{dla } k \neq 2 \\ 1 & \text{dla } k = 2 \end{cases}$$

# Funkcje charakterystyczne

**Twierdzenie:** Jeśli istnieje k-ty moment zmiennej losowej  $X$  to jej funkcja charakterystyczna jest k-krotnie różniczkowalna i zachodzi związek:

$$m_k = \frac{1}{i^k} \frac{d^k}{dt^k} \varphi_X(t) \Big|_{t=0}$$

**Twierdzenie:** Jeśli  $\varphi_X(t)$  jest f. ch. zmiennej  $X$ , to f.ch. zmiennej  $Y = \alpha X + \beta$  dane jest przez

$$\varphi_Y(t) = e^{i\beta t} \varphi_X(\alpha t)$$

**Twierdzenie:** Jeśli  $X$  i  $Y$  są statystycznie niezależnymi zmiennymi losowymi o f. ch. odpowiednio  $\varphi_X(t)$  i  $\varphi_Y(t)$  to f. ch. zmiennej  $X + Y$  dana jest przez

$$\varphi_{X+Y}(t) = \varphi_X(t) \varphi_Y(t)$$

**Przykład:** Znajdź rozkład sumy dwóch zmiennych pochodzących z rozkładów Poissona o parametrach  $\mu_1$  i  $\mu_2$ .

$$\varphi(t) = \exp(\mu(e^{it} - 1))$$

$$\Rightarrow \varphi_k(t) \varphi_l(t) = \exp(\mu_1(e^{it} - 1)) \exp(\mu_2(e^{it} - 1)) = \exp((\mu_1 + \mu_2)(e^{it} - 1))$$

# Warunkowe wartości oczekiwane

Wartością oczekiwaną dyskretnej zmiennej losowej  $k$  pod warunkiem, że zmienna losowa  $m$  przyjmuje wartość  $m$  nazywamy wielkość:

$$\mathcal{E}[k | m = m] \equiv \mu_k(m) \equiv \sum_k k P(k = k | m = m) = \frac{1}{P_{\bullet, m}} \sum_k k P_{km}$$

Wartością oczekiwaną ciągłej zmiennej losowej  $x$  pod warunkiem, że zmienna losowa  $y$  przyjmuje wartość  $y$  nazywamy wielkość:

$$\mathcal{E}[x | y = y] \equiv \mu_x(y) \equiv \int_{-\infty}^{+\infty} x \cdot f(x | y) dx = \frac{1}{f_2(y)} \int_{-\infty}^{+\infty} x \cdot f(x, y) dx$$

Podobnie określamy wartość oczekiwaną dyskretnej zmiennej losowej  $m$  pod warunkiem, że zmienna losowa  $k$  przyjmuje wartość  $k$ :

$$\mathcal{E}[m | k = k] \equiv \mu_m(k) \equiv \sum_m m P(m = m | k = k) = \frac{1}{P_{k, \bullet}} \sum_m m P_{km}$$

oraz wartość oczekiwaną ciągłej zmiennej losowej  $y$  pod warunkiem, że zmienna losowa  $x$  przyjmuje wartość  $x$ :

$$\mathcal{E}[y | x = x] \equiv \mu_y(x) \equiv \int_{-\infty}^{+\infty} y \cdot f(y | x) dy = \frac{1}{f_1(x)} \int_{-\infty}^{+\infty} y \cdot f(x, y) dy$$

# Linie regresji I-go rodzaju

**Linia regresji I-go rodzaju** zmiennej losowej  $k$  ( $x$ ) względem zmiennej losowej  $m$  ( $y$ ) nazywamy zbiór punktów o współrzędnych  $(k,m)$  w przypadku zmiennych dyskretnych i  $(x,y)$  w przypadku zmiennych ciągłych, spełniających równania:

$$k = \mu_k(m) \quad x = \mu_x(y)$$

Analogicznie, **linia regresji I-go rodzaju** zmiennej losowej  $m$  ( $y$ ) względem zmiennej  $k$  ( $x$ ) nazywamy, odpowiednio dla zmiennych dyskretnych i ciągłych, zbiory punktów  $(k,m)$  lub  $(x,y)$ , spełniające równania:

$$m = \mu_m(k) \quad y = \mu_y(x)$$

Własności:

Średnie odchylenie kwadratowe zmiennej losowej  $x$  od pewnej funkcji  $g(y)$  jest najmniejsze, gdy ta funkcja z p-twem 1 jest równa  $\mu_x(y)$ :

$$\mathcal{E} \left[ (x - \mu_x(y))^2 \right] = \min_g \mathcal{E} \left[ (x - g(y))^2 \right]$$

Średnie odchylenie kwadratowe zmiennej losowej  $y$  od pewnej funkcji  $f(x)$  jest najmniejsze, gdy ta funkcja z p-twem 1 jest równa  $\mu_y(x)$ :

$$\mathcal{E} \left[ (y - \mu_y(x))^2 \right] = \min_g \mathcal{E} \left[ (y - f(x))^2 \right]$$



# Linie regresji II-go rodzaju

Linia regresji II-go rodzaju nazywamy zadaną krzywą  $y = h(x; a, b, \dots)$  gdy spełnia ona warunek:

$$\mathcal{E}\left[(y - h(x; a, b, \dots))^2\right] = \min(a, b, \dots)$$

W szczególności prostą regresji II-go rodzaju nazywamy linię prostą  $y = ax + b$  spełniającą warunek:

$$\begin{aligned}\mathcal{E}\left[(y - ax - b)^2\right] &= \mathcal{E}\left[\left((y - \mu_y) - a(x - \mu_x) + \mu_y - a\mu_x - b\right)^2\right] = \\ &= \sigma_y^2 + a^2\sigma_x^2 - 2a \operatorname{cov}[x, y] + (\mu_y - a\mu_x - b)^2 = \sigma_y^2 + a^2\sigma_x^2 - 2a\sigma_x\sigma_y\rho + (\mu_y - a\mu_x - b)^2 = \min(a, b)\end{aligned}$$

Szukamy minimum ze względu na parametry  $a$  i  $b$ :

$$\begin{cases} \frac{\partial}{\partial a} \mathcal{E}\left[(y - ax - b)^2\right] = 2a\sigma_x^2 - 2\sigma_x\sigma_y\rho - 2\mu_x(\mu_y - a\mu_x - b) = 0 \\ \frac{\partial}{\partial b} \mathcal{E}\left[(y - ax - b)^2\right] = -2(\mu_y - a\mu_x - b) = 0 \end{cases} \Rightarrow \begin{cases} a = \rho \frac{\sigma_y}{\sigma_x} \\ b = \mu_y - a\mu_x \end{cases}$$

Prosta regresji II-go rodzaju zmiennej  $y$  względem zmiennej  $x$  ma postać:

$$y = \rho \frac{\sigma_y}{\sigma_x} x - \rho \frac{\sigma_y}{\sigma_x} \mu_x + \mu_y$$

Podobnie znajdujemy prostą regresji II-go rodzaju zmiennej  $x$  względem  $y$ :

$$x = \rho \frac{\sigma_x}{\sigma_y} y - \rho \frac{\sigma_x}{\sigma_y} \mu_y + \mu_x \quad \Rightarrow \quad y = \frac{1}{\rho} \frac{\sigma_y}{\sigma_x} x - \frac{1}{\rho} \frac{\sigma_y}{\sigma_x} \mu_x + \mu_y$$

# Linie regresji I-go rodzaju

**Przykład:** Linie regresji I-go rodzaju dla dwuwymiarowego rozkładu normalnego.

$$\begin{aligned}\mathcal{N}(x, y; \mu_x, \mu_y, \sigma_x, \sigma_y) &= \\ &= \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} \left[ \left( \frac{x-\mu_x}{\sigma_x} \right)^2 + \left( \frac{y-\mu_y}{\sigma_y} \right)^2 - 2\rho \left( \frac{x-\mu_x}{\sigma_x} \right) \left( \frac{y-\mu_y}{\sigma_y} \right) \right] \right\}\end{aligned}$$

**Rozkłady brzegowe to jednowymiarowe rozkłady normalne:**

$$\mathcal{N}_1(x; \mu_x, \sigma_x) = \frac{1}{\sqrt{2\pi}\sigma_x} \exp \left( -\frac{(x-\mu_x)^2}{2\sigma_x^2} \right) \quad \mathcal{E}[x] = \mu_x \quad \mathcal{V}[x] = \sigma_x^2$$

$$\mathcal{N}_2(y; \mu_y, \sigma_y) = \frac{1}{\sqrt{2\pi}\sigma_y} \exp \left( -\frac{(y-\mu_y)^2}{2\sigma_y^2} \right) \quad \mathcal{E}[y] = \mu_y \quad \mathcal{V}[y] = \sigma_y^2$$

**Rozkłady warunkowe i warunkowe wartości oczekiwane:**

$$g(y|x) = \frac{\mathcal{N}(x, y; \mu_x, \mu_y, \sigma_x, \sigma_y)}{\mathcal{N}_1(x; \mu_x, \sigma_x)} = \frac{1}{\sqrt{2\pi}\sigma_y\sqrt{1-\rho^2}} \exp \left( -\frac{1}{2\sigma_y^2(1-\rho^2)} \left[ y - \left( \mu_y + \rho \frac{\sigma_y}{\sigma_x} (x - \mu_x) \right) \right]^2 \right)$$

$$g(x|y) = \frac{\mathcal{N}(x, y; \mu_x, \mu_y, \sigma_x, \sigma_y)}{\mathcal{N}_2(y; \mu_y, \sigma_y)} = \frac{1}{\sqrt{2\pi}\sigma_x\sqrt{1-\rho^2}} \exp \left( -\frac{1}{2\sigma_x^2(1-\rho^2)} \left[ x - \left( \mu_x + \rho \frac{\sigma_x}{\sigma_y} (y - \mu_y) \right) \right]^2 \right)$$

# Linie regresji I-go rodzaju

Linie regresji I-go rodzaju to proste o równaniach:

$$y = \mathcal{E}[y | x] = \mu_y + \rho \frac{\sigma_y}{\sigma_x} (x - \mu_x)$$

$$x = \mathcal{E}[x | y] = \mu_x + \rho \frac{\sigma_x}{\sigma_y} (y - \mu_y) \quad \Rightarrow \quad y = \mu_y + \frac{1}{\rho} \frac{\sigma_y}{\sigma_x} (x - \mu_x)$$

Uwaga: W przypadku dwuwymiarowego rozkładu normalnego, linie regresji I-go rodzaju są jednocześnie prostymi regresji II-go rodzaju.

# Linie regresji I-go rodzaju

**Przykład:** Chcemy umieć przewidzieć wzrost pewnego gatunku żyta na podstawie koncentracji fosforu w glebie. W tym celu badany cztery koncentracje 2, 4, 8, 16 ppm fosforu, i obserwujemy wzrost roślin przy każdej z nich począwszy od nasiona aż do momentu kwitnienia. Następnie dokonujemy pomiaru suchej masy każdej z roślin. Wyniki pomiarów przedstawia tabela.

Roślina	Fosfor [ppm]	Masa [g]
1	2	4.1
2	2	3.8
3	2	4.0
4	2	3.9
5	4	5.2
6	4	4.9
7	4	5.0
8	4	4.8
9	8	5.7
10	8	5.9
11	8	6.0
12	8	6.2
13	16	11.7
14	16	8.9
15	16	10.1
16	16	10.3

Zmienne losowe:  $x$  - koncentrację fosforu,  $y$  - masa roślin.

$$\mu_x \equiv \mathcal{E}[x] = \frac{1}{16}(4 \times 2 + 4 \times 4 + 4 \times 8 + 4 \times 16) = 7.5$$

$$\mu_y \equiv \mathcal{E}[y] = \frac{1}{16}(4.1 + 3.8 + 4.0 + 3.9 + 5.2 + 4.9 + 5.0 + 4.8 + 5.7$$

$$+ 5.9 + 6.0 + 6.2 + 11.7 + 8.9 + 10.1 + 10.3) = \frac{100.5}{16} \approx 6.28$$

$$\mathcal{E}[x^2] = \frac{1360}{16} = 85 \quad \mathcal{E}[y^2] = \frac{727.49}{16} = 45.468 \quad \mathcal{E}[xy] = \frac{957.6}{16} = 59.85$$

$$\text{cov}[x, y] = \mathcal{E}[xy] - \mathcal{E}[x]\mathcal{E}[y] = 59.85 - 7.5 \times 6.28 = 12.75$$

$$\mathcal{D}[x] = \sqrt{\mathcal{E}[x^2] - (\mathcal{E}[x])^2} = \sqrt{85 - 7.5^2} = 5.36$$

$$\mathcal{D}[y] = \sqrt{\mathcal{E}[y^2] - (\mathcal{E}[y])^2} = \sqrt{45.468 - 6.28^2} = 2.46$$

$$\rho = \frac{\text{cov}[x, y]}{\mathcal{D}[x]\mathcal{D}[y]} = 0.967$$

$$y = 0.44x + 2.96$$