

# Metody probabilistyczne

## Rozwiązania zadań

### 10. Ciągłe zmienne losowe II

13.01.2021

**Zadanie 1.** Rozważ zmienne  $(X, Y)$  o gęstości łącznej:

$$f(x, y) = \begin{cases} c(x+y) & x, y \in [0, 1] \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

Oblicz stałą  $c$ , gęstości brzegowe i warunkowe.

*Odpowiedź:* Korzystając z warunku normalizacji gęstości obliczamy stałą  $c$ :

$$\begin{aligned} 1 &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) \, dx \, dy = \int_0^1 \int_0^1 c(x+y) \, dx \, dy \\ &= c \int_0^1 \int_0^1 x \, dx \, dy + c \int_0^1 \int_0^1 y \, dx \, dy \\ &= c \int_0^1 \underbrace{\left( \int_0^1 dy \right)}_{=1} x \, dx + c \int_0^1 \underbrace{\left( \int_0^1 dx \right)}_{=1} y \, dy \\ &= c \frac{1}{2} x^2 \Big|_0^1 + c \frac{1}{2} y^2 \Big|_0^1 = \frac{1}{2} c + \frac{1}{2} c = c, \end{aligned}$$

z czego wynika, że  $c = 1$ , a więc  $f(x, y) = x + y$  dla  $x, y \in [0, 1]$ . Wyznaczmy teraz gęstości brzegowe:

$$f_X(x) = \int_{-\infty}^{\infty} f(x, y) \, dy = \int_0^1 (x+y) \, dy = x \int_0^1 dy + \int_0^1 y \, dy = x + \frac{1}{2} y^2 \Big|_0^1 = x + \frac{1}{2}.$$

Z symetrii gęstości ze względu na  $x$  i  $y$  otrzymujemy również  $f_Y(y) = y + \frac{1}{2}$ . Wyznaczamy na koniec gęstości warunkowe:

$$f_{Y|X}(y|x) = \frac{f(x, y)}{f_X(x)} = \frac{x+y}{x+\frac{1}{2}}.$$

Z symetrii zagadnienia mamy również  $f_{X|Y}(x|y) = \frac{x+y}{y+\frac{1}{2}}$ .

**Zadanie 2.** Losujemy punkt jednostajnie z koła o promieniu 1. Innymi słowy mamy parę zmiennych  $(X, Y)$  o gęstości łącznej:

$$f(x, y) = \begin{cases} c & x^2 + y^2 \leq 1 \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

Oblicz stałą  $c$  i gęstości brzegowe.

*Odpowiedź:* Obliczenie stałej  $c$  nie jest trudne, jeśli zauważymy, że całka gęstości to po prostu  $c$  razy pole koła o promieniu 1, czyli  $\pi c$ . Ponieważ musi to być równe jeden, otrzymujemy  $c = \frac{1}{\pi}$ .

Ponieważ rozkład jest całkowicie symetryczny ze względu na  $x$  i  $y$ , wystarczy policzyć jeden z rozkładów brzegowych, np. po  $x$ . Z definicji:

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

Dla zadanego  $x$ , funkcja gęstości jest niezerowa (i równa  $\frac{1}{\pi}$ ) tylko wtedy, gdy  $x^2 + y^2 \leq 1$ . Nierówność ta jest spełniona dla  $y$  z przedziału  $[-\sqrt{1-x^2}, \sqrt{1-x^2}]$ , a więc:

$$f_X(x) = \int_{-\sqrt{1-x^2}}^{\sqrt{1-x^2}} \frac{1}{\pi} dy = \frac{1}{\pi} y \Big|_{-\sqrt{1-x^2}}^{\sqrt{1-x^2}} = \frac{2\sqrt{1-x^2}}{\pi}.$$

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

*Dygresja:* Zauważmy, że sprawdzenie normalizacji rozkładu brzegowe  $f_X(x)$  nie jest łatwe! Trzeba wykonać całkę na przedziale  $[-1, 1]$  (wartości, które może przyjąć  $x$ ), tzn.:

$$\begin{aligned} \int_{-1}^1 \frac{2\sqrt{1-x^2}}{\pi} dx &= \left| \begin{array}{l} x = \cos \alpha \\ dx = -\sin \alpha d\alpha \end{array} \right| = -\frac{2}{\pi} \int_{\pi}^0 \sqrt{1-\cos^2 \alpha} \sin \alpha d\alpha \\ &= \frac{2}{\pi} \int_0^{\pi} |\sin \alpha| \sin \alpha d\alpha = \frac{2}{\pi} \int_0^{\pi} \sin^2 \alpha d\alpha \\ &= \frac{2}{\pi} \int_0^{\pi} \frac{1-\cos(2\alpha)}{2} d\alpha = \frac{2}{\pi} \int_0^{\pi} \frac{1}{2} d\alpha + \frac{2}{\pi} \int_0^{\pi} \cos(2\alpha) d\alpha \\ &= \left| \begin{array}{l} \beta = 2\alpha \\ d\beta = 2 d\alpha \end{array} \right| = 1 + \frac{2}{\pi} \int_0^{2\pi} \cos(\beta) \frac{1}{2} d\beta \\ &= 1 + \frac{1}{\pi} \sin(\beta) \Big|_0^{2\pi} = 1. \end{aligned}$$

**Zadanie 3.** Niech  $X_1, \dots, X_n$  będą niezależnymi zmiennymi losowymi o tym samym rozkładzie opisanym dystrybucją  $F_X$ . Wyznacz dystrybuanty zmiennych  $Y = \max\{X_1, \dots, X_n\}$  oraz  $Z = \min\{X_1, \dots, X_n\}$ .

*Odpowiedź:*

1. Dystrybuanta  $F_Y$  zmienne  $Y$ :

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(\max\{X_1, \dots, X_n\} \leq y) \\ &= P(X_1 \leq y, X_2 \leq y, \dots, X_n \leq y) \\ &\stackrel{(*)}{=} P(X_1 \leq y) \cdot P(X_2 \leq y) \cdot \dots \cdot P(X_n \leq y) = F_X(y)^n, \end{aligned}$$

gdzie w (\*) wykorzystaliśmy niezależność  $X_1, \dots, X_n$ .

2. Dystrybuanta  $F_Z$  zmienne  $Z$ :

$$\begin{aligned} F_Z(z) &= P(Z \leq z) = 1 - P(Z > z) = 1 - P(\min\{X_1, \dots, X_n\} > z) \\ &= 1 - P(X_1 > z, X_2 > z, \dots, X_n > z) \\ &\stackrel{(*)}{=} 1 - P(X_1 > z) \cdot P(X_2 > z) \cdot \dots \cdot P(X_n > z) \\ &= 1 - (1 - P(X_1 \leq z)) \cdot (1 - P(X_2 \leq z)) \cdot \dots \cdot (1 - P(X_n \leq z)) \\ &= 1 - (1 - F_X(z))^n, \end{aligned}$$

gdzie w (\*) wykorzystaliśmy niezależność  $X_1, \dots, X_n$ .

**Zadanie 4.** Zmienne losowe  $X$  i  $Y$  są niezależne, o rozkładzie wykładniczym, tzn.  $X \sim \text{Exp}(\lambda_X)$  oraz  $Y \sim \text{Exp}(\lambda_Y)$ . Wyznacz rozkład zmiennej  $Z = \min\{X, Y\}$ . Wskazówka: trzeba wpierv uogólnić wzór na minimum zmiennych niezależnych, ale o różnym rozkładzie.

*Odpowiedź:* Rozpocniemy od wyznaczenia wzoru na dystrybucję minimum dwóch zmiennych losowych niezależnych (ale niekoniecznie o tym samym rozkładzie). Jest to bardzo podobne wyprowadzenie do tego w poprzednim zadaniu. Niech  $Z = \min\{X, Y\}$ , gdzie  $X$  i  $Y$  są niezależne. Mamy:

$$\begin{aligned} P(Z > z) &= P(\min\{X, Y\} > z) = P(X > z, Y > z) = P(X > z)P(Y > z) \\ &= (1 - P(X \leq z))(1 - P(Y \leq z)) = (1 - F_X(z))(1 - F_Y(z)), \end{aligned}$$

a stąd:

$$F_Z(z) = P(Z \leq z) = 1 - P(Z > z) = 1 - (1 - F_X(z))(1 - F_Y(z)).$$

Jeśli  $X \sim \text{Exp}(\lambda)$ , to dystrybuanta  $F_X$  dana jest wzorem:

$$F_X(x) = 1 - e^{-\lambda x}.$$

Podobnie  $F_Y(y) = 1 - e^{-\lambda_Y y}$ , a więc:

$$F_Z(z) = 1 - e^{-\lambda_X z} e^{-\lambda_Y z} = 1 - e^{-(\lambda_X + \lambda_Y)z}.$$

Ale to jest dystrybuanta rozkładu wykładniczego o parametrze  $\lambda_X + \lambda_Y$ . Tym samym  $Z \sim \text{Exp}(\lambda_X + \lambda_Y)$ .

**Zadanie 5\*.** Rozważ dwie niezależne zmienne losowe  $X \sim N(\mu_X, \sigma_X^2)$  oraz  $Y \sim N(\mu_Y, \sigma_Y^2)$ . Wyznacz gęstość zmiennej  $Z = X + Y$ .

*Odpowiedź:* Gęstość  $f_Z$  zmiennej  $Z$  jest splotem gęstości  $f_X$  i  $f_Y$ :

$$f_Z(z) = \int_{-\infty}^{\infty} f_X(t) f_Y(z-t) dt \quad (1)$$

$$= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma_X^2}} \exp\left\{-\frac{(t-\mu_X)^2}{2\sigma_X^2}\right\} \frac{1}{\sqrt{2\pi\sigma_Y^2}} \exp\left\{-\frac{(z-t-\mu_Y)^2}{2\sigma_Y^2}\right\} dt$$

$$= \frac{1}{\sqrt{2\pi\sigma_X^2}} \frac{1}{\sqrt{2\pi\sigma_Y^2}} \int_{-\infty}^{\infty} \exp\left\{-\frac{(t-\mu_X)^2}{2\sigma_X^2} - \frac{(z-t-\mu_Y)^2}{2\sigma_Y^2}\right\} dt. \quad (2)$$

Aby policzyć tę całkę, spróbujemy uprościć wykładnik (wyrażenie w exp) w (2):

$$\begin{aligned} -\frac{(t-\mu_X)^2}{2\sigma_X^2} - \frac{(z-t-\mu_Y)^2}{2\sigma_Y^2} &= -\frac{(t-\mu_X)^2\sigma_Y^2 + ((z-\mu_Y)-t)^2\sigma_X^2}{2\sigma_X^2\sigma_Y^2} \\ &= -\frac{t^2(\sigma_X^2 + \sigma_Y^2) - 2t(\mu_X\sigma_Y^2 + (z-\mu_Y)\sigma_X^2) + \mu_X^2\sigma_Y^2 + (z-\mu_Y)^2\sigma_X^2}{2\sigma_X^2\sigma_Y^2}. \end{aligned} \quad (3)$$

Zauważmy, że w liczniku w (3) mamy wyrażenie kwadratowe (ze względu na  $t$ ) postaci:

$$at^2 - 2tb + c,$$

gdzie:

$$a = \sigma_X^2 + \sigma_Y^2, \quad b = \mu_X\sigma_Y^2 + (z-\mu_Y)\sigma_X^2, \quad c = \mu_X^2\sigma_Y^2 + (z-\mu_Y)^2\sigma_X^2 \quad (4)$$

Chcielibyśmy je zamienić na bardziej zwartą postać  $a(t-d)^2 + r$ . Jak znaleźć  $d$  i  $r$ ? Wystarczy oba wyrażenia przyrównać:

$$at^2 - 2tb + c = a(t-d)^2 + r = at^2 - 2tad + ad^2 + r.$$

Ponieważ wyrażenia przy kolejnych potęgach  $t$  muszą być sobie równe, dostaniemy:

$$b = ad, \quad c = ad^2 + r \quad \implies \quad d = \frac{b}{a}, \quad r = c - ad^2 = c - \frac{b^2}{a}.$$

Czyli:

$$\begin{aligned} d &= \frac{\mu_X\sigma_Y^2 + (z-\mu_Y)\sigma_X^2}{\sigma_X^2 + \sigma_Y^2} \\ r &= \mu_X^2\sigma_Y^2 + (z-\mu_Y)^2\sigma_X^2 - \frac{(\mu_X\sigma_Y^2 + (z-\mu_Y)\sigma_X^2)^2}{\sigma_X^2 + \sigma_Y^2} \\ &= \frac{\mu_X^2\sigma_Y^4 + (z-\mu_Y)^2\sigma_X^4 + \sigma_X^2\sigma_Y^2(\mu_X^2 + (z-\mu_Y)^2) - (\mu_X\sigma_Y^2 + (z-\mu_Y)\sigma_X^2)^2}{\sigma_X^2 + \sigma_Y^2} \\ &= \frac{\sigma_X^2\sigma_Y^2(\mu_X^2 + (z-\mu_Y)^2) - 2\mu_X\sigma_Y^2(z-\mu_Y)\sigma_X^2}{\sigma_X^2 + \sigma_Y^2} \\ &= \frac{\sigma_X^2\sigma_Y^2}{\sigma_X^2 + \sigma_Y^2} (\mu_X^2 + (z-\mu_Y)^2 - 2\mu_X(z-\mu_Y)) = \frac{\sigma_X^2\sigma_Y^2}{\sigma_X^2 + \sigma_Y^2} (z-\mu_X-\mu_Y)^2. \end{aligned} \quad (5)$$

Ułamek po prawej stronie równania (3) ma więc postać:

$$-\frac{a(t-d)^2 + r}{2\sigma_X^2 \sigma_Y^2},$$

a tym samym całka w (2) wygląda następująco:

$$\begin{aligned} \int_{-\infty}^{\infty} \exp\left\{-\frac{a(t-d)^2 + r}{2\sigma_X^2 \sigma_Y^2}\right\} dt &= \int_{-\infty}^{\infty} \exp\left\{-\frac{a(t-d)^2}{2\sigma_X^2 \sigma_Y^2}\right\} \exp\left\{-\frac{r}{2\sigma_X^2 \sigma_Y^2}\right\} dt \\ &= \exp\left\{-\frac{r}{2\sigma_X^2 \sigma_Y^2}\right\} \int_{-\infty}^{\infty} \exp\left\{-\frac{a(t-d)^2}{2\sigma_X^2 \sigma_Y^2}\right\} dt. \end{aligned} \quad (6)$$

Mając dowolny rozkład normalny o parametrach  $\mu$  i  $\sigma^2$ , gęstość rozkładu musi się normalizować do 1, tzn:

$$\frac{1}{\sqrt{2\pi\sigma^2}} \int_{-\infty}^{\infty} \exp\left\{-\frac{(t-\mu)^2}{2\sigma^2}\right\} dt = 1,$$

z czego wynika:

$$\int_{-\infty}^{\infty} \exp\left\{-\frac{(t-\mu)^2}{2\sigma^2}\right\} dt = \sqrt{2\pi\sigma^2} \quad (7)$$

Zauważmy teraz, że całka po prawej stronie (6) jest dokładnie postaci (7), jeśli przyrównamy  $\mu = d$  oraz  $\sigma^2 = \frac{\sigma_X^2 \sigma_Y^2}{a}$ . Tym samym dostajemy:

$$\int_{-\infty}^{\infty} \exp\left\{-\frac{a(t-d)^2}{2\sigma_X^2 \sigma_Y^2}\right\} dt = \sqrt{2\pi \frac{\sigma_X^2 \sigma_Y^2}{a}} = \sqrt{2\pi \frac{\sigma_X^2 \sigma_Y^2}{\sigma_X^2 + \sigma_Y^2}},$$

gdzie w ostatniej równości podstawiliśmy wartość  $a$  z (4). Wykorzystując definicję  $r$  z (5), dostajemy:

$$\exp\left\{-\frac{r}{2\sigma_X^2 \sigma_Y^2}\right\} = \exp\left\{-\frac{\cancel{\sigma_X^2} \cancel{\sigma_Y^2} (z - \mu_X - \mu_Y)^2}{2\cancel{\sigma_X^2} \cancel{\sigma_Y^2} (\sigma_X^2 + \sigma_Y^2)}\right\} = \exp\left\{-\frac{(z - \mu_X - \mu_Y)^2}{2(\sigma_X^2 + \sigma_Y^2)}\right\}.$$

Możemy więc zapisać prawą stronę (6) jako:

$$\exp\left\{-\frac{(z - \mu_X - \mu_Y)^2}{2(\sigma_X^2 + \sigma_Y^2)}\right\} \sqrt{2\pi \frac{\sigma_X^2 \sigma_Y^2}{\sigma_X^2 + \sigma_Y^2}}.$$

Podstawiając to do (2) dostajemy:

$$\begin{aligned} f_Z(z) &= \frac{1}{\sqrt{2\pi\sigma_X^2}} \frac{1}{\sqrt{2\pi\sigma_Y^2}} \exp\left\{-\frac{(z - \mu_X - \mu_Y)^2}{2(\sigma_X^2 + \sigma_Y^2)}\right\} \sqrt{2\pi \frac{\sigma_X^2 \sigma_Y^2}{\sigma_X^2 + \sigma_Y^2}} \\ &= \sqrt{\frac{2\pi \cancel{\sigma_X^2} \cancel{\sigma_Y^2}}{\sigma_X^2 + \sigma_Y^2} \frac{1}{2\pi \cancel{\sigma_X^2}} \frac{1}{2\pi \cancel{\sigma_Y^2}}} \\ &= \frac{1}{\sqrt{2\pi(\sigma_X^2 + \sigma_Y^2)}} \exp\left\{-\frac{(z - \mu_X - \mu_Y)^2}{2(\sigma_X^2 + \sigma_Y^2)}\right\}. \end{aligned}$$

Ale to ostatnie wyrażenie ma postać gęstości rozkładu normalnego z parametrami  $\mu = \mu_X + \mu_Y$  i  $\sigma^2 = \sigma_X^2 + \sigma_Y^2$ . Czyli:

$$Z \sim N(\mu_X + \mu_Y, \sigma_X^2 + \sigma_Y^2).$$