

# 1 Analiza rozkładu

## 1.1 Miary położenia

- Średnia arytmetyczna

$$\bar{x} = \frac{1}{N} \sum_i x_i = \frac{1}{N} \sum_i x_i n_i = \sum_i x_i w_i$$

gdzie  $n_i$  to liczba wystąpień  $x_i$ , a  $w_i$  - częstość wystąpień (waga).

- Średnia geometryczna

$$\bar{x} = \sqrt[n]{x_1 x_2 \dots x_n}$$

- Średnia harmoniczna

$$\bar{x} = \frac{1}{\frac{1}{N} \sum_i \frac{1}{x_i}}$$

- moda (dominanta): wartość występująca najczęściej (o największej wartości funkcji gęstości prawdopodobieństwa)

- mediana: wartość, od której połowa obserwacji jest mniejsza i połowa - większa

- kwartyle i kwantyle: kwantyl rzędu  $\frac{i}{j}$  - taka liczba, że  $\frac{i}{j}$  wyników jest mniejsza od tej liczby. Kwartyle 1 ( $q_1$ ) i 3 ( $q_3$ ) to odpowiednio kwantyle rzędu 1/4 i 3/4.

## 1.2 Miary zróżnicowania

- wariancja (moment centralny rzędu 2):

$$\sigma = \frac{1}{N} \sum_i (x_i - \bar{x})^2 = \frac{1}{N} \sum_i n_i (x_i - \bar{x})^2$$

lub

$$\sigma = \sum_i w_i (x_i - \bar{x})^2$$

- odchylenie standardowe średniej:

$$s = \sqrt{\sigma}$$

- rozstęp: różnica między największą i najmniejszą wartością wyników

- rozstęp ćwiartkowy:

$$IQR = q_3 - q_1$$

- odchylenie ćwiartkowe:

$$o = \frac{IQR}{2}$$

## 1.3 Miary asymetrii i koncentracji

- moment centralny rzędu 3:

$$M_3 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^3 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^3 n_i$$

- współczynniki skośności:

(a)

$$A_d = \frac{\mu - d}{s}$$

(b)

$$A_m = 3 \frac{\mu - d}{s} = 3A_d$$

(c)

$$A_Q = \frac{Q_1 + Q_3 - 2m}{2Q}$$

- Współczynnik asymetrii

$$A = \frac{M_3}{s^3}$$

## 1.4 Rozkłady

- Gęstość  $f(t)$  i dystrybuanta  $F(x)$

(a)

$$f(t) \geq 0$$

,

$$F(x) \geq 0$$

,

(b) dystrybuanta

$$F(x) = \int_{-\infty}^x f(t) dt$$

, w  $-\infty = 0$  a w  $+\infty = 1$ ,

(c)

$$f(x) = F'(x)$$

gdy pochodna istnieje i 0 w przeciwnym przypadku,

(d)

$$\int_{-\infty}^{\infty} f(t) dt = 1$$

- normalizacja gęstości, prawdopodobieństwo że zajdzie jakiegokolwiek zdarzenie jest równe 1,

- (e) prawdopodobieństwo, że  $X$  jest większe od  $a$  i mniejsze od  $b$ :

$$P(a \leq X \leq b) = F(b) - F(a) = \int_a^b f(x) dx$$

- funkcje zmiennej losowej ciągłej: jeśli funkcja  $g(x)$  ma odwrotną funkcję  $h(y)$  taką, że  $h(g(X)) = X$  (np  $g(x) = \log x$  ma odwrotną  $e^y$ , bo  $e^{\log x} = x$ , to gęstość zmiennej losowej  $Y = g(X)$  wyraża się wzorem

$$f[h(y)] | h'(y)|$$

w przedziale  $(g(a), g(b))$  (zakładamy, że  $g(a) < g(b)$ ),

- entropia

$$H(X) = - \sum_i p_i \log(p_i)$$

, przy czym w zależności od podstawy logarytmu są różne jednostki entropii. Dla podstawy 2 jednostką jest bit. Entropia jest równa zero, gdy rozkład jest jednopunktowy (zmienna przyjmuje tylko jedną wartość) i przyjmuje maksymalną wartość  $\log n$  gdy rozkład jest jednostajny (każdy wynik jest jednakowo prawdopodobny),

## 1.5 zmienne dwuwymiarowe

- gęstość  $f(x, y)$  jest nieujemna,

- dystrybuanta  $F(x, y) = P(X < x, Y < y)$ ,

- dystrybuanty rozkładów brzegowych  $F_x(x, \infty)$  i  $F_y(\infty, y)$ ,

- dystrybuanta zmiennej skokowej

$$F(x, y) = \sum_i \sum_j p_{ij}$$

, gdzie dla każdego  $i, j$  zachodzi  $x_i < x, y_j < y$ ,

- dystrybuanta zmiennej ciągłej

$$F(x, y) = \int_{-\infty}^x \left( \int_{-\infty}^y f(t, u) du \right) dt$$

- całka z gęstości po całej przestrzeni = 1, tj

$$F(\infty, \infty) = \int_{-\infty}^{\infty} \left( \int_{-\infty}^{\infty} f(t, u) du \right) dt = 1$$

- $f(x, y) = \frac{\partial^2}{\partial x \partial y} F(x, y)$  o ile taka pochodna istnieje lub 0,

$$8. P(a < X < b, c < Y < d) = \int_a^b \left( \int_c^d f(x, y) dy \right) dx,$$

## 1.6 rozkłady brzegowe i warunkowe

- $P(X = x_i, Y = y_j) = p_{ij}$ ,

$$2. P(X = x_i) = p_{i.} = \sum_j p_{ij},$$

$$3. P(Y = y_j) = p_{.j} = \sum_i p_{ij},$$

$$4. f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy - \text{gęstość rozkł. brzeg. zm. X,}$$

$$5. f_Y(y) = \int_{-\infty}^{\infty} f(x, y) dx - \text{gęstość rozkł. brzeg. zm. Y,}$$

$$6. P(X = x_i, Y = y_j) = p_{ij},$$

- prawdopodobieństwo wystąpienia  $x_i$  jeżeli wystąpiło  $y_j$  wynosi:

$$P(X = x_i | Y = y_j) = \frac{P(X = x_i, Y = y_j)}{P(Y = y_j)} = \frac{p_{ij}}{p_{.j}}$$

i odpowiednio, symetrycznie w odwrotnym przypadku. Analogicznie dla rozkładów ciągłych:

$$f_X(x | y_0) = \frac{F(x, y_0)}{f_Y(y_0)}$$

i symetrycznie - odwrotnie,

## 1.7 zmienne losowe niezależne

Jeżeli

$$F(x, y) = F_X(x) F_Y(y)$$

to zmienne  $X, Y$  nazywamy niezależnymi. Wystarczy nawet, że

$$p_{ij} = p_{i.} p_{.j}$$

dla każdej pary  $(x_i, y_j)$ . Dla zmiennej ciągłej analogicznie  $f(x, y) = f_X(x) f_Y(y)$  w każdym punkcie  $f(x, y)$ .