

PSK - materiały do zajęć na 26.05.2020

Temat Wektor losowy i jego własności.

Obserwuj zmienną losową  $(\Omega, \Sigma, P)$ . To jest parę interwenta naj tylko jeden aspekt tej obserwacji, który był opisywany zmienną losową  $X$ .

Teraz założymy, że każdy aspekt będzie  $m \geq 2$ , czyli będącymi  $m$  zmiennymi losowymi:

$X_1, X_2, \dots, X_n$ , każdy z nich obserwowany na  $\Omega$ , a więc interpretujemy obserwację  $ZL$ .

Będącymi  $m$  zmiennymi losowymi efekt agregacji tych aspektów w postaci obiektu  $(X_1, \dots, X_n)$ , który nazywamy wektorem losowym.

Zatem wynikiem tej agregacji  $p$  przyporządkowane:

$$\Omega \ni \omega \longrightarrow (X_1, \dots, X_n)(\omega) = (X_1(\omega), \dots, X_n(\omega)),$$

które obserwacje  $\omega \in \Omega$  przyporządkowane ciąg liczb

$(x_1, x_2, \dots, x_n)$ , który też nazywamy wektorem

W tym sensie możemy powiedzieć, że wektor losowy jest: uogólnieniem (zmyślnym) wektora, ale i też (pojedynczej) zmienną losową.



Opisem probabilistycznym wielka losowego jest jego wzrostek,  
który możemy wzrostkiem taczonym w. l.

Jest nim funkcja  $n$ -argumentowa  $F_{(X_1, \dots, X_n)}$

$$\mathbb{R}^n \rightarrow (t_1, t_2, \dots, t_n) \longrightarrow F_{(X_1, X_2, \dots, X_n)}(t_1, t_2, \dots, t_n) =$$

$$= P(\{\omega \in \Omega : X_1(\omega) < t_1 \wedge X_2(\omega) < t_2 \wedge \dots \wedge X_n(\omega) < t_n\})$$

Zatem uogólnienie (zwykły) dystybuencyjny wzrostek.

Nyjsimym znaczenie tej funkcji ograniczamy przypadki do  $n=2$ ,  
czyli wielka paracji  $(X, Y)$  zaczynając od przypadków  
dyskretnych.

### I Przypadki dyskretny (skontyng)

Nich  $X, Y$  opisują wyniki obserwacji ZL  $(\Omega, \mathcal{F}, P)$   
następująco:

$$X(\omega) = \{x_1, x_2, \dots, x_m\}$$

$$Y(\omega) = \{y_1, y_2, \dots, y_m\}, \quad n, m \geq 2.$$

Niech taczony wynik obserwacji danych wielkorem losowym  $(X, Y)$   
ma utworzyc

$$(X, Y)(\omega) = \{(x_i, y_j), \quad i=1, \dots, m, \quad j=1, 2, \dots, m\}.$$



Fornulme many funkcji

$$F_{(X,Y)}(t,s) = P(\omega \in \Omega : X(\omega) \leq t \wedge Y(\omega) \leq s)$$

której w omawianej sytuacji można przedstawić inaczej.

W tym celu weźmy partycję  $\mathcal{C}$ :

$$C_{ij} = \{ \omega \in \Omega : (X(\omega), Y(\omega)) = (x_i, y_j) \},$$

$$i = 1, 2, \dots, n; \quad j = 1, 2, \dots, m.$$

Oznaczmy  $p_{ij} = P(C_{ij})$  oraz weźmy macierz  $P$

typu  $n \times m$ , gdzie  $P = [p_{ij}]_{n \times m} = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1m} \\ p_{21} & p_{22} & \dots & p_{2m} \\ \dots & \dots & \dots & \dots \\ p_{n1} & p_{n2} & \dots & p_{nm} \end{bmatrix}$ .

Zauważmy, że:

1)  $p_{ij} \in (0, 1)$  dla każdego  $i, j$

2) podzbiór  $\{C_{ij}\}$  to partycja  $\Omega$ , zatem  
wszystkie  $p_{ij}$  to dodatnie, czyli  $\sum_{j=1}^m \sum_{i=1}^n p_{ij} = 1$

3) oznaczmy sumę współczynników ~~elementów~~ <sup>wyrazów</sup>  $i$ -tego wiersza macierzy  $P$  przez  $P_i$ . Analogicznie, sumę współczynników współczynników  $j$ -tego kolumny macierzy  $P$  przez  $P_j$



Wtedy ciąg:

$$(P_{1.}, P_{2.}, \dots, P_{n.}) \text{ oraz } (P_{.1}, P_{.2}, \dots, P_{.m})$$

określają rozkład składowy  $X_i, Y$  wektor  $(X, Y)$ , czyli:

$$P(\text{zwektor: } X(u) = x_i) = P_{i.}, \quad i = 1, 2, \dots, n$$

$$P(\text{zwektor: } Y(v) = y_j) = P_{.j}, \quad j = 1, \dots, m.$$

Zatem macierz  $\Pi$  reprezentująca rozkład (ciąg) wektora losowego  $(X, Y)$ , będąca alternatywną postacią funkcji  $F_{(X, Y)}$  wyznacza rozkład  $X, Y$ . Z tego powodu rozkład jest rozkładem brzegowymi.

▼ uwaga. Aby nie odwrócić, fun. znamionosi' rozkładu brzegowych nie daje rozkładu trójnego.

W jednym było przypadek TAK JEST:

Kiedy  $X, Y$  są stochastycznie niezależne.

Wtedy

$$P_{ij} = P_{i.} \cdot P_{.j}$$



- 5 -

h) I na odwrót, jeśli dam  $p$  macierz

$A = [a_{ij}]_{n \times m}$   $p$  wierszami 1-3, 6

a) istnie ZL  $(\omega, \bar{z}, P)$

b) zmienię losowe  $X, Y$

c) wektór losowy  $(X, Y)$ ,  $\bar{z}$   $A$  opisuje jego rozkład.

Przykład 1.

Niech  $X(\omega) = \{-1, 1\}$ ,  $Y(\omega) = \{0, 2\}$

Bierny  $(X, Y)$  i zadany,  $P$   $A$  jego rozkładem tęcy: Mamy następującą symetrię:

$$P = \begin{matrix} -1 & 1 \\ 0 & 2 \end{matrix} \begin{matrix} 0,3 & 0,1 \\ 0,3 & 0,3 \end{matrix} \begin{matrix} P_{11} = 0,1 \\ P_{21} = 0,6 \\ P_{12} = 0,6 \\ P_{22} = 0,4 \end{matrix}$$

Zatem  $X: \begin{array}{c|c} -1 & 1 \\ \hline 0,4 & 0,6 \end{array} ; Y: \begin{array}{c|c} 0 & 2 \\ \hline 0,6 & 0,4 \end{array}$

Sprawdź, czy  $X, Y$  są stochast. niezależne.



Пример 2

Дана система уравнений вида  $a, b, c$ ,  
где матрица  $A$  имеет заданные значения  $p$ . Найти  
решение.

$$\begin{bmatrix} a & b & c \\ 1/6 & 1/6 & 1/6 \\ 1/12 & 1/12 & 1/12 \end{bmatrix}$$

Нужно найти решение. Для этого нужно решить  
систему уравнений.

Решение

Заметим, что матрица имеет вид  $X(\Omega), Y(\Omega)$ .

Дано также матрица  $X(\Omega) = \{x_1, x_2, x_3\}$

$Y(\Omega) = \{y_1, y_2, y_3\}$

то требуется найти  $U, P, A$ , где

$$\begin{matrix} x_1 \\ x_2 \\ x_3 \end{matrix} \begin{bmatrix} y_1 & y_2 & y_3 \\ a & b & c \\ 1/6 & 1/6 & 1/6 \\ 1/12 & 1/12 & 1/12 \end{bmatrix}$$



ii) Pomysłowość ciągłej.

Niech  $X, Y$  mają rozkład ciągły z funkcjami gęstości  $f_X$  oraz  $f_Y$ , czyli

$$F_X(t) = \int_{-\infty}^t f_X(u) du, \quad F_Y(s) = \int_{-\infty}^s f_Y(v) dv.$$

Wtedy rozkład (ciągły) wektora  $(X, Y)$  określony jest następująco

$$F_{(X, Y)}(t, s) = \int_{-\infty}^s \left( \int_{-\infty}^t f_{(X, Y)}(u, v) du \right) dv,$$

gdzie funkcja  $f_{(X, Y)}$  jest odpowiednim rozkładem  $P$  z punktów rozkładu dyskretnego i nazywana jest gęstością rozkładu  $(X, Y)$ .

Uwaga. Na ogół

$$f_{(X, Y)} \neq f_X \cdot f_Y.$$

Jaki ~~podział~~ rodzaj zachodni, to  $X, Y$  są stochastycznie niezależne.



Ogarnijmy się tylko do dwóch przykładów

P.1. Niech  $f(t,s) = \begin{cases} \frac{1}{(b-a)(d-c)} & , (t,s) \in [a,b] \times [c,d] \\ 0 & \text{dla pozostałych} \end{cases}$

Pomocno  $f(t,s) \geq 0$  oraz  $\int_{-\infty}^{+\infty} \left( \int_{-\infty}^{+\infty} f(t,s) ds \right) dt = 1$ ,

niech  $f$  będzie funkcją gęstości pewnego wektora  $(X,Y)$  i. e. w

$B_1$   $f = f(x,y)$ . Biorąc

$f_X$  dla  $X \in \mathcal{G}(L[a,b])$ ,  $f_Y$  dla  $Y \in \mathcal{G}(L[c,d])$

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

P.2. (dwuwymiarowy rozkład normalny)

$(X,Y)$  ma dwuwymiarowy rozkład normalny, gdzie

$$f_{(X,Y)}(t,s) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left( \frac{(t-m_1)^2}{\sigma_1^2} - 2\rho \frac{(t-m_1)(s-m_2)}{\sigma_1\sigma_2} + \frac{(s-m_2)^2}{\sigma_2^2} \right)\right)$$

dla pewnych  $m_1, m_2 \in \mathbb{R}^2$

$$\sigma_1, \sigma_2 > 0, \quad |\rho| < 1$$

Ważny wyjątek zwrócić uwagę na linię  $\rho$  !



Temat. Kowariancja i współczynnik korelacji

Wiemy, że na ogół rozkład łączny nie jest wyznaczony przez rozkłady brzegowe. Mamy tylko

rozkład łączny  $\implies$  rozkład brzegowy.

Pomocnym tu jest brak stochastycznej niezależności. Potrzebna jest miara stopnia zależności  $X$  od  $Y$  (ograniczony jest tylko do wektora  $(X, Y)$ !).

I krok konstrukcji tej miary: pojęcie kowariancji.

Należy dążyć do wektora  $(X, Y)$ , gdzie  $X, Y$  mają co najmniej 2-te momenty (a więc i warianse).

Przez kowariancję  $(X, Y)$  rozumimy

$$\text{cov}(X, Y) = E((X - EX)(Y - EY))$$

Uwaga 1°. Jeśli  $X = Y$ , to

$$\text{cov}(X, X) = \text{var}(X)$$



2<sup>v</sup>. Bezpośrednim rachunkiem (prosy go  
wykonać) można sprawdzić, że

$$\text{cov}(X, Y) = E(XY) - (EX)(EY).$$

3<sup>v</sup>. Jeśli  $X, Y$  są stochastycznie niezależne, to

$$E(XY) = (EX)(EY), \text{ zatem z 2}^{\text{v}}.$$

$$\text{stochastycznie niezależni } X, Y \Rightarrow \text{cov}(X, Y) = 0$$

4<sup>v</sup>. Bezpośrednim rachunkiem można sprawdzić  
(zrobić to) że

$$\text{var}(X+Y) = \text{var}(X) + \text{var}(Y) + 2 \text{cov}(X, Y).$$

Zatem:

$$X, Y \text{ st. niezależne} \Rightarrow \text{cov}(X, Y) = 0 \Rightarrow \text{var}(X+Y) = \text{var}(X) + \text{var}(Y)$$

5<sup>v</sup>. Z tego, że  $\text{cov}(X, Y) = 0$  nie wynika  
stochastyczna niezależność.

Dlatego  $\text{cov}(X, Y) = 0$  występuje jako miernik  
stochastycznej zależności!



II etap konstrukcji

Niech dajmy  $X, Y$  dodatkowo  $\neq$  const.

Niech  $\text{var} X > 0, \text{var} Y > 0$ .

Definicja

$$\rho(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{var} X} \cdot \sqrt{\text{var} Y}}$$

Jest to tw. współczynnik KORELACJI współzależnych  
zmiennych losowych  $(X, Y)$ .

Własności  $\rho(X, Y)$ :

a)  $X=Y, b \quad \rho(X, X) = 1$

$X=-Y, b \quad \rho(X, -X) = -1$

b) ogólnie  $\rho(X, Y) \in [-1, 1]$ .

c) dajmy bieżący  $|\rho(X, Y)| \in [0, 1]$ .

Niech

$|\rho(X, Y)| = 1$  (oznacza najzu. możliwą  
zależność)

$\Downarrow$   
 $Y = aX + b$  dla p.  $a \neq 0$  i  $b \in \mathbb{R}$



Czyli' pewnym najwzrostem' zależnośc (stochastyczn)'  
X od Y (Y od X) jest zmniejszanie wymiaru

$$Y = aX + b$$

$$d) |R(X,Y)| = 0 \equiv \text{cov}(X,Y) = 0$$

$$\equiv \text{var}(X+Y) = \text{var}(X) + \text{var}(Y)$$



na rozproszenie pomiaru temperatury, wpływ  
tylko rozproszenie jego składników.  
Brak efektu „zarzucenia”

Przykład

Wektory  $(X_i, Y_i)$  ma rozkład teny

$$P = \begin{matrix} & \begin{matrix} 0 & 1 & 2 \end{matrix} \\ \begin{matrix} 0 \\ 1 \\ 2 \end{matrix} & \begin{bmatrix} 0 & 1/4 & 0 \\ 1/4 & 0 & 1/4 \\ 0 & 1/4 & 0 \end{bmatrix} \end{matrix}, \text{ gde } X(\omega) = Y(\omega) = \{0, 1, 2\}$$

z tablicami

X:	<table border="1"><tr><td>0</td><td>1</td><td>2</td></tr><tr><td>1/4</td><td>1/2</td><td>1/4</td></tr></table>	0	1	2	1/4	1/2	1/4	Y:	<table border="1"><tr><td>0</td><td>1</td><td>2</td></tr><tr><td>1/4</td><td>1/2</td><td>1/4</td></tr></table>	0	1	2	1/4	1/2	1/4
0	1	2													
1/4	1/2	1/4													
0	1	2													
1/4	1/2	1/4													

czyli'  $d(X) = d(Y)$ , zatem  $X$  i  $Y$  me sę  
stochastycznie niezależne.



-13-

Obliz  $\text{cov}(X, Y)$  i  $\mathcal{L}(X, Y)$ .

$$EX = EY = 1.$$

Daj<sup>u</sup>  $(X, Y)(\omega) = \{0, 1, 2, 3\}$  i varijablu  $XY$   
u istom prostoru.

$$XY: \begin{array}{c|c|c|c} 0 & 1 & 2 & 3 \\ \hline 1/2 & 0 & 1/2 & 0 \end{array} = \begin{array}{c|c} 0 & 2 \\ \hline 1/2 & 1/2 \end{array}$$

Dakle  $E(XY) = 1$ .

Stoga  $\text{cov}(X, Y) = E(XY) - \underbrace{(EX)(EY)} = 0$

odakle  $|\mathcal{L}(X, Y)| = 0$ .

Zaključujemo da  $X$  i  $Y$  nisu linearno zavisne.

Stoga, i  $d(X) = d(Y)$  !





Temat. Warunka wartości oczekiwanej.

Nyjmijmy to pojście najpierw dla  $p$ . dyskretnego.

Nach  $(X, Y)$  - dyskretny (skorowany) wektor losowy.

$$X(\omega) = \{x_1, x_2, \dots, x_n\}, \quad Y(\omega) = \{y_1, y_2, \dots, y_m\}$$

$$P = [p_{ij}]_{n \times m} \text{ - macierz } p_{ij}$$

$$E(X | Y=y) = \sum_{i=1}^n x_i \cdot P(\omega \in \Omega : X(\omega) = x_i | Y(\omega) = y)$$

↓  
warunka w. oczekiwanej  $X$   
pod warunkiem, że zawsze  
zdarzenie  $\{\omega \in \Omega : Y(\omega) = y\}$ ,  
 $y \in Y(\Omega)$

Z def. modelu warunkowa mamy:

$$E(X | Y=y) = \frac{\sum_{i=1}^n x_i \cdot P(\omega \in \Omega : (X(\omega), Y(\omega)) = (x_i, y))}{P(\omega \in \Omega : Y(\omega) = y)}$$

Jeśli  $y \in Y(\Omega)$ , czyli  $y = y_j$  dla pewnego  $1 \leq j \leq m$ , to

$$E(X | Y=y_j) = \frac{\sum_{i=1}^n x_i \cdot p_{ij}}{p_{\cdot j}} = \sum_{i=1}^n x_i \cdot \frac{p_{ij}}{p_{\cdot j}}$$



Zauważmy, że

$$w_{ij} = \frac{p_{ij}}{p_{.j}} \in (0,1) \text{ oraz}$$

$$\sum_{i=1}^m w_{ij} = \frac{p_{.j}}{p_{.j}} = 1.$$

Dlatego

$E(X | Y = y_j)$  jest średnią ważoną

wartości  $X(\omega)$ , gdzie wagi (dla  $y_j$ )

są postaciami  $w_{ij}$ .

Przykład. Niech  $\omega \in \Omega$ ,  $X(\omega) = \{1, 2, 3\}$ ,  $Y(\omega) = \{-1, 1\}$   
i rozkład teny ma postać

$$P = \begin{matrix} & \begin{matrix} -1 & 1 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \end{matrix} & \begin{bmatrix} \frac{12}{50} & \frac{1}{10} \\ \frac{8}{50} & \frac{13}{50} \\ \frac{3}{50} & \frac{1}{5} \end{bmatrix} \end{matrix}$$

Zatem

$$X: \begin{array}{c|cc|c} & 1 & 2 & 3 \\ \hline \frac{16}{50} & \frac{21}{50} & \frac{13}{50} \end{array}$$

$$Y: \begin{array}{c|c} -1 & 1 \\ \hline \frac{22}{50} & \frac{28}{50} \end{array}$$

Wyznaczyć np.  $E(X | Y = -1)$



~~definiert p.1. Kette z. d. Kette~~  
-16-

Zugabe 2. definieren man:

$$E(X | Y=1) = \sum_{i=1}^n x_i \cdot \frac{P_{ij}}{P_{i.}} =$$

$$= \cancel{x_1} \frac{P_{11}}{P_{.1}} + x_2 \frac{P_{21}}{P_{.1}} + x_3 \frac{P_{31}}{P_{.1}}$$

$$= 1 \cdot \frac{11}{50} \frac{50}{22} + 2 \cdot \frac{8}{50} \frac{50}{22} + 3 \cdot \frac{2}{50} \frac{50}{22}$$

$$= \frac{1}{2} + \frac{16}{22} + \frac{9}{22} = \frac{36}{22}$$

Formel für die

$$E(X | Y=y) = \frac{\int_{\mathbb{R}} x f(x,y) dx}{\int_{\mathbb{R}} f(x,y) dx}$$