

Poprzednim razem

$$cov(X, Y) = E[(X - E(X))(Y - E(Y))] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - E(X))(y - E(Y))f_{X,Y}(x, y) dx dy$$

$$\rho_{X,Y} \equiv \rho(X, Y) \equiv corr(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X)var(Y)}}$$

$$-1 \leq \rho_{X,Y} \leq 1$$

$$\rho_{X,Y} = 1 \quad \text{dla } Y = aX + b \quad a > 0$$

$$\rho_{X,Y} = -1 \quad \text{dla } Y = aX + b \quad a < 0$$

1

<http://tylervigen.com/spurious-correlations>

Worldwide non-commercial space launches correlates with Sociology doctorates awarded (US)

RPIS 2024/2025 115

2

<http://tylervigen.com/spurious-correlations>

Number of people who drowned by falling into a pool correlates with Films Nicolas Cage appeared in

Korelacje przypadkowe (falszywe) czy prawdziwe?

Analiza ekspercka
 Zmienne współzależne: $X \rightarrow Y, X \rightarrow Z$ prowadzi do korelacji (Y, Z)
 Zmienne pośredniczące: $X \rightarrow Y \rightarrow Z$ prowadzi do korelacji (X, Z)
 Analiza zebrania próby: zmienne kontrolne, badania z randomizacją, dobór próby
 Analiza wyników: grupowanie, analiza regresji, analiza wariancji, sieci zależności

RPIS 2024/2025 116

3

Wektor losowy – przypadek $n > 2$

- Syt.: dany jest n -wymiarowy wektor losowy \vec{X} , z którego tworzymy wielowymiarową zmienną losową \vec{Y} :
 $\vec{Y} = \vec{Y}(\vec{X})$

rozwijamy wokół $Y = E(X)$, zostawiając czony liniowe

$$Y_i = \frac{Y_i(E(\vec{X}))}{E(Y_i)} + \sum_j \left(\frac{\partial Y_i}{\partial X_j} \right)_{\vec{X}=E(\vec{X})} (X_j - E(X_j)) + \dots$$

$$Y_i - E(Y_i) = \sum_j \left(\frac{\partial Y_i}{\partial X_j} \right)_{\vec{X}=E(\vec{X})} (X_j - E(X_j))$$

RPIS 2024/2025 4

4

Prawo przenoszenia błędów

$$cov(Y_k, Y_q) = E[(Y_k - E(Y_k))(Y_q - E(Y_q))] = E \left[\sum_i \left(\frac{\partial Y_k}{\partial X_i} \right)_{\vec{X}=E(\vec{X})} (X_i - E(X_i)) \sum_m \left(\frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} (X_m - E(X_m)) \right] = \sum_{i,m} \left(\frac{\partial Y_k}{\partial X_i} \right)_{\vec{X}=E(\vec{X})} \left(\frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} E[(X_i - E(X_i))(X_m - E(X_m))] = \sum_{i,m} \left(\frac{\partial Y_k}{\partial X_i} \right)_{\vec{X}=E(\vec{X})} \left(\frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} cov(X_i, X_m)$$

$$[C(X)]_{j,m} \equiv cov(X_j, X_m); [C(Y)]_{k,q} \equiv cov(Y_k, Y_q); T_{i,j} \equiv \left(\frac{\partial Y_i}{\partial X_j} \right)_{\vec{X}=E(\vec{X})}$$

$$[C(Y)]_{k,q} = \sum_{i,m} T_{k,i} T_{q,m} [C(X)]_{j,m} = \sum_{i,m} T_{k,i} [C(X)]_{j,m} T_{q,m}^T$$

$$C(Y) = TC(X)T^T \quad \leftarrow \text{macierzowo}$$

RPIS 2024/2025 5

5

Prawo przenoszenia błędów - przykład

$$cov(Y_k, Y_q) = \sum_{i,m} \left(\frac{\partial Y_k}{\partial X_i} \right)_{\vec{X}=E(\vec{X})} \left(\frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} cov(X_i, X_m)$$

- Zał: Y_k (nowa zmienna) zależy od X_1, \dots, X_N (stare zmienne).
 Dokonujemy pomiaru wszystkich X_i otrzymując $E(X_i)$ oraz $\sigma(X_i)$

$$\sigma(Y_k) = \sqrt{var(Y_k)} = \sqrt{cov(Y_k, Y_k)} = \sqrt{\sum_{i,m} \left(\frac{\partial Y_k}{\partial X_i} \right)_{\vec{X}=E(\vec{X})} \left(\frac{\partial Y_k}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} cov(X_i, X_m)} = \dots$$

X_i i X_m niezależne $\rightarrow cov(X_i, X_m) = 0$

$$\dots = \sqrt{\sum_i \left(\frac{\partial Y_k}{\partial X_i} \right)_{\vec{X}=E(\vec{X})}^2 cov(X_i, X_i)} = \sqrt{\sum_i \left(\frac{\partial Y_k}{\partial X_i} \right)_{\vec{X}=E(\vec{X})}^2 (\sigma(X_i))^2}$$

RPIS 2024/2025 6

6

Transformacje wektorów losowych

- Syt. $\vec{Z} = g(\vec{X})$
- Przypadek dyskretny: grupujemy te wartości \vec{X} , które dają te same wartości \vec{Z} i dodajemy prawdopodobieństwa. Otrzymujemy rozkład prawdopodobieństwa wektora losowego \vec{Z} .
- Przypadek ciągły:
 - I sposób: (zał. Z jest jednowymiarowe czyli $Z = g(X_1, X_2, \dots, X_n)$)

$$F_Z(z) = \int \dots \int f_{\vec{X}}(x_1, x_2, \dots, x_n) dx_1 \dots dx_n$$

po wszystkich zdarzeniach dla których $Z(A) \leq z$

Znając dystrybuantę obliczamy (łącną) funkcję gęstości prawdopodobieństwa.
 Dla Z n-wymiarowej całkujemy po wszystkich zdarzeniach dla których $Z_1(A) \leq z_1 \wedge Z_2(A) \leq z_2 \wedge \dots \wedge Z_n(A) \leq z_n$.

RPiS 2024/2025 7

7

Transformacje wektorów losowych

- Przypadek ciągły:
 - II sposób:
 - zał.:
 - 1. $n=2$ czyli $(X,Y) \rightarrow (V,W)$ czyli $V=g_1(X,Y)$, $W=g_2(X,Y)$
 - 2. istnieją jednoznaczne funkcje $h_1: X=h_1(V,W)$ i $h_2: Y=h_2(V,W)$
 - 3. dla każdego x,y funkcje g_1 i g_2 mają ciągłe pochodne cząstkowe
 - 4. Jacobian

$$J_{(x,y)} \equiv \begin{vmatrix} \frac{\partial g_1}{\partial x} & \frac{\partial g_1}{\partial y} \\ \frac{\partial g_2}{\partial x} & \frac{\partial g_2}{\partial y} \end{vmatrix} \neq 0$$

Wtedy

$$f_{V,W}(v,w) = f_{X,Y}(x(v,w), y(v,w)) |J_{(x,y)}|^{-1}$$

RPiS 2024/2025 8

8

Transformacje wektorów losowych - przykład

- Niezależne zmienne losowe X,Y mają rozkłady jednorodne na (0,1). Znaleźć łączną funkcję gęstości prawdopodobieństwa zmiennych $V = \sqrt{-2\ln(X)} \cos(2\pi Y)$ oraz $W = \sqrt{-2\ln(X)} \sin(2\pi Y)$
- Rozwiązanie:
 - Z treści zadania: $f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y) = 1 \cdot 1 = 1$

Potrzebujemy: $f_{V,W}(v,w) = f_{X,Y}(x(v,w), y(v,w)) |J_{(x,y)}|^{-1}$

Liczymy

$$\frac{\partial x}{\partial v} = \frac{\partial}{\partial v} (\sqrt{-2\ln(X)} \cos(2\pi Y)) = \cos(2\pi Y) \frac{\partial}{\partial v} (\sqrt{-2\ln(X)}) = \frac{\cos(2\pi Y)}{2\sqrt{-2\ln(X)}} \cdot \frac{(-2)}{X}$$

$$\frac{\partial x}{\partial w} = \frac{\partial}{\partial w} (\sqrt{-2\ln(X)} \cos(2\pi Y)) = \sqrt{-2\ln(X)} \frac{\partial}{\partial w} (\cos(2\pi Y)) = \sqrt{-2\ln(X)} \cdot (-1) \sin(2\pi Y) \cdot 2\pi$$

$$\frac{\partial y}{\partial v} = \frac{\partial}{\partial v} (\sqrt{-2\ln(X)} \sin(2\pi Y)) = \sin(2\pi Y) \frac{\partial}{\partial v} (\sqrt{-2\ln(X)}) = \frac{\sin(2\pi Y)}{2\sqrt{-2\ln(X)}} \cdot \frac{(-2)}{X}$$

$$\frac{\partial y}{\partial w} = \frac{\partial}{\partial w} (\sqrt{-2\ln(X)} \sin(2\pi Y)) = \sqrt{-2\ln(X)} \frac{\partial}{\partial w} (\sin(2\pi Y)) = \sqrt{-2\ln(X)} \cdot \cos(2\pi Y) \cdot 2\pi$$

RPiS 2024/2025 9

9

Transformacje wektorów losowych - przykład

$V = \sqrt{-2\ln(X)} \cos(2\pi Y)$
 $W = \sqrt{-2\ln(X)} \sin(2\pi Y)$

$$J_{(x,y)} = \det \begin{pmatrix} \frac{\partial v}{\partial x} & \frac{\partial v}{\partial y} \\ \frac{\partial w}{\partial x} & \frac{\partial w}{\partial y} \end{pmatrix} = \frac{\partial v}{\partial x} \frac{\partial w}{\partial y} - \frac{\partial v}{\partial y} \frac{\partial w}{\partial x} = (\cos(2\pi Y))^2 \cdot \frac{(-2)}{X^2} - (\sin(2\pi Y))^2 \cdot \frac{(-2)}{X^2} = \frac{(-2)}{X^2} ((\cos(2\pi Y))^2 + (\sin(2\pi Y))^2) = \frac{(-2)}{X^2}$$

$$|J_{(x,y)}|^{-1} = \left| \frac{(-2)}{X^2} \right|^{-1} = \left(\frac{2}{X} \right)^2 = \frac{4}{X^2}$$

$$V^2 + W^2 = (\sqrt{-2\ln(X)} \cos(2\pi Y))^2 + (\sqrt{-2\ln(X)} \sin(2\pi Y))^2 = (-2\ln(X)) = -2\ln(X)$$

$$\rightarrow X = e^{\frac{-(V^2+W^2)}{2}} \rightarrow |J_{(x,y)}|^{-1} = \frac{4}{X^2} = \frac{4}{e^{-(V^2+W^2)}} = \frac{1}{2} e^{\frac{-(V^2+W^2)}{2}}$$

$$\rightarrow f_{v,w}(v,w) = f_{x,y}(x(v,w), y(v,w)) |J_{(x,y)}|^{-1} = 1 \cdot \frac{1}{2} e^{\frac{-(v^2+w^2)}{2}} = \frac{1}{2} e^{\frac{-(v^2+w^2)}{2}}$$

$$\rightarrow f_{v,w}(v,w) = \frac{1}{2\pi} e^{-\frac{v^2+w^2}{2}} = N_v(0,1) \cdot N_w(0,1) = f_v(v) \cdot f_w(w)$$

Dwa niezależne rozkłady $N(0,1)$

RPiS 2024/2025 10

10

Transformacja Box-Mullera

- X_1, X_2 mają rozkłady jednorodne na przedziale (0,1); wtedy $Y_1 = \sqrt{-2\ln(X_1)} \cos(2\pi X_2)$ i $Y_2 = \sqrt{-2\ln(X_1)} \sin(2\pi X_2)$ mają rozkłady $N(0,1)$.

RPiS 2024/2025 11

11

Wielowymiarowy rozkład normalny

- Łączna gęstość prawdopodobieństwa

$$f_{\vec{X}}(\vec{x}) = \left(\frac{\det(K^{-1})}{(2\pi)^n} \right)^{1/2} e^{-\frac{1}{2}(\vec{x}-\vec{a})^T K^{-1}(\vec{x}-\vec{a})}$$
 - \vec{X} - wektor n zmiennych losowych
 - K - macierz kowariancji n x n
 - \vec{a} - stały wektor n liczb ($E(\vec{X}) = \vec{a}$)
- dla $n=2$

$$K^{-1} = \frac{1}{\text{var}(X_1)\text{var}(X_2) - (\text{cov}(X_1, X_2))^2} \begin{pmatrix} \text{var}(X_2) & -\text{cov}(X_1, X_2) \\ -\text{cov}(X_1, X_2) & \text{var}(X_1) \end{pmatrix}$$
- Standaryzacja $U_i = \frac{X_i - a_i}{\sigma(X_i)}$ dla $n=2$ prowadzi do
 - ρ to współczynnik korelacji u_1 i u_2
 - $K^{-1} = \frac{1}{1-\rho^2} \begin{pmatrix} 1 & -\rho \\ -\rho & 1 \end{pmatrix}$

$$f_{\vec{U}}(u_1, u_2) = \left(\frac{\det(K^{-1})}{(2\pi)^2} \right)^{1/2} e^{-\frac{1}{2} \vec{u}^T K^{-1} \vec{u}}$$

RPiS 2024/2025 12

12

Wielowymiarowy rozkład normalny - elipsa kowariancji

- Łączna gęstość prawdopodobieństwa

$$f_{\vec{u}}(u_1, u_2) = \text{const} \rightarrow \vec{u}^T K^{-1} \vec{u} = \text{const} \rightarrow$$

$$\frac{1}{1-\rho^2} (u_1^2 + u_2^2 - 2u_1 u_2 \rho) = \text{const} \rightarrow$$

$$\frac{1}{1-\rho^2} \left(\frac{(x_1 - a_1)^2}{(\sigma(X_1))^2} + \frac{(x_2 - a_2)^2}{(\sigma(X_2))^2} - 2\rho \frac{(x_1 - a_1)}{\sigma(X_1)} \frac{(x_2 - a_2)}{\sigma(X_2)} \right) = \text{const}$$

- Jest to równanie elipsy zwanej dla $\text{const}=1$ elipsą kowariancji. Prawdopodobieństwo wystąpienia zmiennych losowych wewnątrz elipsy kowariancji jest niezależne od $\sigma(X_1), \sigma(X_2)$ i ρ .

RPIS 2024/2025 13