

# Analiza wielowymiarowa

Analiza korelacji

Zmienne kanoniczne

Analiza składowych głównych

Analiza czynnikowa

Analiza skupień

Analiza dyskryminacyjna

## Analiza korelacji

Obserwujemy wektor losowy  $(Y, X_1, \dots, X_k)$

Macierz kowariancji

$$\mathcal{C} = \begin{bmatrix} C_{YY} & C_{YX_1} & C_{YX_2} & \cdots & C_{YX_k} \\ C_{YX_1} & C_{X_1X_1} & C_{X_1X_2} & \cdots & C_{X_1X_k} \\ \vdots & \vdots & \vdots & & \vdots \\ C_{YX_k} & C_{X_1X_k} & C_{X_2X_k} & \cdots & C_{X_kX_k} \end{bmatrix}$$

Macierz korelacji

$$\mathcal{R} = \begin{bmatrix} 1 & r_{YX_1} & r_{YX_2} & \cdots & r_{YX_k} \\ r_{YX_1} & 1 & r_{X_1X_2} & \cdots & r_{X_1X_k} \\ \vdots & \vdots & \vdots & & \vdots \\ r_{YX_k} & r_{X_1X_k} & r_{X_2X_k} & \cdots & 1 \end{bmatrix}$$

$$\frac{1}{\sqrt{(2\pi)^n \det \mathcal{C}}} \exp \left[ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})' \mathcal{C}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right]$$

## Elipsoida koncentracji

$$(\mathbf{x} - \boldsymbol{\mu})' \mathcal{C}^{-1} (\mathbf{x} - \boldsymbol{\mu}) = \text{const}$$


---

$$\mathcal{C} = \begin{bmatrix} \sigma_{11}^2 & \rho \sigma_{11} \sigma_{22} \\ \rho \sigma_{11} \sigma_{22} & \sigma_{22}^2 \end{bmatrix}$$

$$\frac{1}{2} \left( \sigma_{11}^2 + \sigma_{22}^2 - \sqrt{(\sigma_{11}^2 - \sigma_{22}^2)^2 + 4\rho^2 \sigma_{11}^2 \sigma_{22}^2} \right),$$

$$\frac{1}{2} \left( \sigma_{11}^2 + \sigma_{22}^2 + \sqrt{(\sigma_{11}^2 - \sigma_{22}^2)^2 + 4\rho^2 \sigma_{11}^2 \sigma_{22}^2} \right),$$


$$\left[ \frac{\sigma_{11}^2 - \sigma_{22}^2 - \sqrt{(\sigma_{11}^2 - \sigma_{22}^2)^2 + 4\rho^2 \sigma_{11}^2 \sigma_{22}^2}}{2\rho \sigma_{11} \sigma_{22}}, 1 \right],$$

$$\left[ \frac{\sigma_{11}^2 - \sigma_{22}^2 + \sqrt{(\sigma_{11}^2 - \sigma_{22}^2)^2 + 4\rho^2 \sigma_{11}^2 \sigma_{22}^2}}{2\rho \sigma_{11} \sigma_{22}}, 1 \right],$$

$$C = \begin{bmatrix} 1 & \rho \\ \rho & 1 \end{bmatrix}$$

$$1 - \rho \quad 1 + \rho$$

$$[-1, 1] \quad [1, 1]$$



## Współczynnik korelacji wielokrotnej między $Y$ a $(X_1, X_2, \dots, X_k)$

$$r_{Y|X_1, X_2, \dots, X_k} = \max_{\lambda_1, \lambda_2, \dots, \lambda_k} r(Y, \lambda_1 X_1 + \lambda_2 X_2 + \dots + \lambda_k X_k)$$

1.  $r_{Y|X_1, X_2, \dots, X_k} \in \langle 0, 1 \rangle$
2.  $r_{Y|X_1, X_2, \dots, X_k} = 0$ :  
 $Y$  średnio nie jest zależne od  $(X_1, X_2, \dots, X_k)$
3.  $r_{Y|X_1, X_2, \dots, X_k} = 1$ :  
 $Y$  jest liniową funkcją  $(X_1, X_2, \dots, X_k)$

$$r_{Y|X_1, X_2, \dots, X_k} = \sqrt{1 - \frac{|\mathcal{R}|}{|\mathcal{R}_{11}|}}$$

.....

$$\frac{r_{Y|X_1, X_2, \dots, X_k}^2}{1 - r_{Y|X_1, X_2, \dots, X_k}^2} \cdot \frac{n - k + 1}{k - 1} \sim F_{k-1, n-k+1}$$

## Współczynnik korelacji cząstkowej

$r_{YX_1(X_2 \dots X_k)}$  opisuje zależność pomiędzy  $Y$  oraz  $X_1$  z wyłączeniem pozostałych zmiennych

$$e_i = Y_i - (\hat{\beta}_0 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + \dots + \hat{\beta}_k X_{ki})$$

$$e_i^* = X_{1i} - (\hat{\alpha}_0 + \hat{\alpha}_2 X_{2i} + \hat{\alpha}_3 X_{3i} + \dots + \hat{\alpha}_k X_{ki})$$

$$i = 1, 2, \dots, n$$

$$r_{YX_1(X_2 \dots X_k)} = r_{ee^*}$$

$$\mathcal{R}^{-1} = \begin{bmatrix} r^{YY} & r^{YX_1} & r^{YX_2} & \dots & r^{YX_k} \\ r^{YX_1} & r^{X_1X_1} & r^{X_1X_2} & \dots & r^{X_1X_k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r^{YX_k} & r^{X_1X_k} & r^{X_2X_k} & \dots & r^{X_kX_k} \end{bmatrix}$$

$$r_{YX_1(X_2 \dots X_k)} = - \frac{r^{YX_1}}{\sqrt{r^{YY} r^{X_1X_1}}}$$

.....

$$\frac{r_{YX_1(X_2 \dots X_k)}}{\sqrt{1 - r_{YX_1(X_2 \dots X_k)}^2}} \sqrt{n - k + 1} \sim t_{n-k+1}$$

## Liniowa funkcja regresji

$$E(Y|\mathbf{X} = \mathbf{x}) = \beta_0 + \sum_{j=1}^k \beta_j x_j$$

$$\boldsymbol{\beta}' = [\beta_0, \beta_1, \dots, \beta_k]$$

$$\hat{\boldsymbol{\beta}} = (\boldsymbol{\mathcal{X}}' \boldsymbol{\mathcal{X}})^{-1} \boldsymbol{\mathcal{X}}' \mathbf{y}$$

$$\mathbf{y}' = [Y_1, Y_2, \dots, Y_n]$$

$$\boldsymbol{\mathcal{X}} = \begin{bmatrix} 1 & X_{11} & X_{21} & \dots & X_{k1} \\ 1 & X_{12} & X_{22} & \dots & X_{k2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & X_{1n} & X_{2n} & \dots & X_{kn} \end{bmatrix}$$

Wariancja resztowa

$$\frac{1}{n-k} \mathbf{y}' (\mathbf{I} - \boldsymbol{\mathcal{X}} (\boldsymbol{\mathcal{X}}' \boldsymbol{\mathcal{X}})^{-1} \boldsymbol{\mathcal{X}}) \mathbf{y}$$

**Przykład.** Badano zależność wydatków na artykuły spożywcze, papierosy oraz alkohol. Zbadać istnienie zależności między obserwowanymi cechami. Jeżeli taka zależność istnieje, to dokonać ilościowego opisu zależności wydatków na artykuły spożywcze od wydatków na papierosy i alkohol.

---

$Y$ : wydatki na artykuły spożywcze

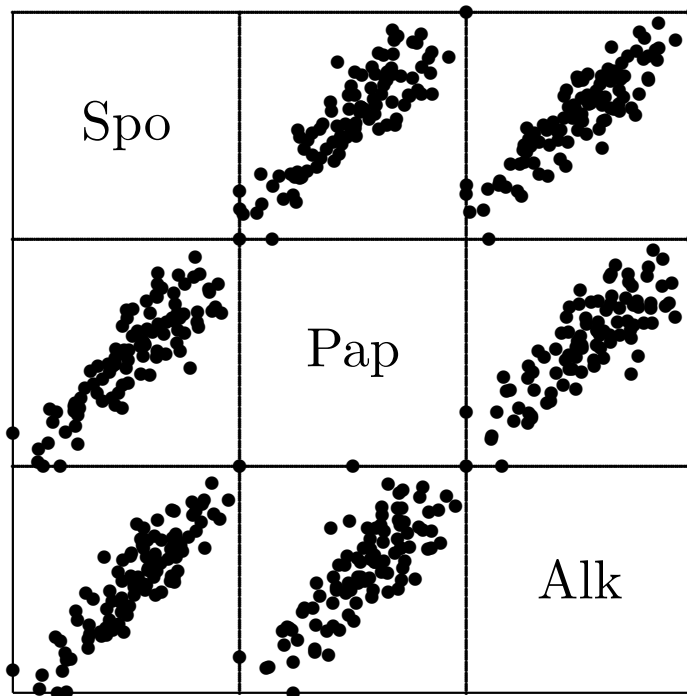

$X_1$ : wydatki na papierosy

$X_2$ : wydatki na alkohol

$$\mathcal{R} = \begin{bmatrix} 1.0000 & 0.8717 & 0.8914 \\ 0.8717 & 1.0000 & 0.8267 \\ 0.8914 & 0.8267 & 1.0000 \end{bmatrix}$$

$$\mathcal{R}^{-1} = \begin{bmatrix} 6.7557 & -2.8763 & -3.6442 \\ -2.8763 & 4.3835 & -1.0599 \\ -3.6442 & -1.0599 & 5.1247 \end{bmatrix}$$





## Współczynnik korelacji wielokrotnej

$$|\mathcal{R}| = 0.0469$$

$$|\mathcal{R}_{11}| = \left| \begin{bmatrix} 1.0000 & 0.8267 \\ 0.8267 & 1.0000 \end{bmatrix} \right| = 0.3165$$

$$r_{Y|X_1, X_2} = \sqrt{1 - \frac{|\mathcal{R}|}{|\mathcal{R}_{11}|}} = \sqrt{1 - \frac{0.0469}{0.3165}} = 0.9230$$

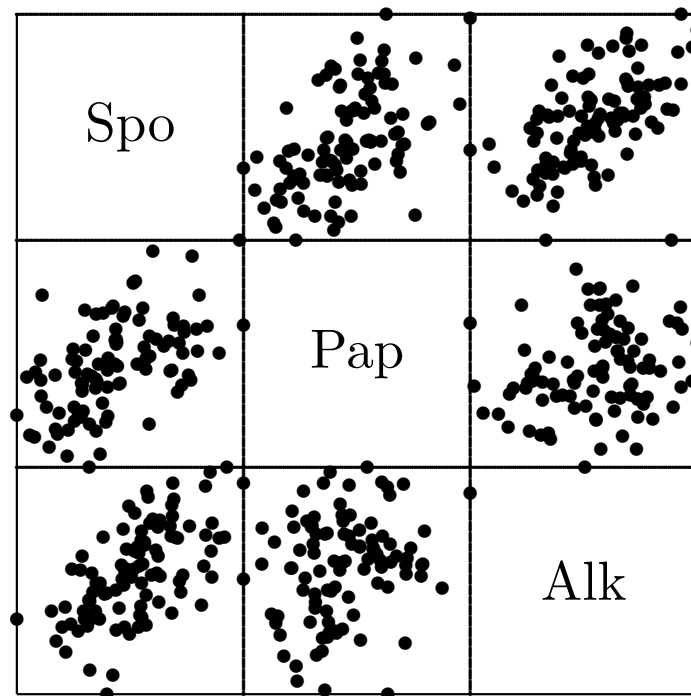
$$p - \text{value} \approx 0.003577$$

## Współczynniki korelacji cząstkowych

$$r_{Y X_1(X_2)} = -\frac{-2.8763}{\sqrt{6.7557 \cdot 4.3835}} = 0.5284$$

$$r_{Y X_2(X_1)} = -\frac{-3.6442}{\sqrt{6.7557 \cdot 5.1247}} = 0.6957$$

$$r_{X_1 X_2(Y)} = -\frac{-1.0599}{\sqrt{4.3835 \cdot 5.1247}} = 0.2236$$



## Ocena parametrów funkcji regresji

$$f(x_1, x_2) = \beta_0 + \beta_1 x_1 + \beta_2 x_2$$



$$\hat{\beta}_0 = 41.072954$$

$$\hat{\beta}_1 = 0.131759$$

$$\hat{\beta}_2 = 0.129004$$


## Wariancja resztowa

$$S^2 = 0.151115$$



.....

*Przykład.* Badano zależność między zmienną  $Y$  a zmiennymi  $X_1, X_2, X_3$ . Dokonano  $n = 100$  obserwacji.



$$\mathcal{R} = \begin{bmatrix} 1.000 & 0.884 & 0.885 & 0.887 \\ 0.884 & 1.000 & 0.988 & 0.980 \\ 0.885 & 0.988 & 1.000 & 0.990 \\ 0.887 & 0.980 & 0.990 & 1.000 \end{bmatrix}$$


$$r_{Y|X_1, X_2, X_3} = 0.8902$$

$$\mathcal{R}^{-1} = \begin{bmatrix} 4.819 & -1.775 & -0.083 & -2.453 \\ -1.775 & 44.187 & -40.182 & -1.940 \\ -0.083 & -40.182 & 87.816 & -47.497 \\ -2.453 & -1.940 & -47.497 & 52.103 \end{bmatrix}$$

$$r_{Y X_1(X_2, X_3)} = 0.1217$$

$$r_{Y X_2(X_1, X_3)} = 0.0040$$

$$r_{Y X_3(X_1, X_2)} = 0.1548$$



.....