


KORRELACE A REGRESE

$(x_1, y_1), \dots, (x_n, y_n)$



$$y - \bar{y} = \frac{k}{s_x^2} (x - \bar{x})$$

1. regresevní přímka

$$k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

$$R = \frac{k}{s_x \cdot s_y}$$

některý
korelační
koeficient

$$|R| = 1$$

Kovariance a korelační koeficient

$(\Omega, \mathcal{Y}, \mathcal{P})$

necht \bar{X}, \bar{Y} jsou náhodné prom.

Víme, že

$$E(a + bX) = a + bE(X), \quad a, b \in \mathbb{R}$$

$$E(X + Y) = E(X) + E(Y)$$

$$D(a + bX) = b^2 \cdot D(X)$$

$$D(X+Y) = D(X) + D(Y) + 2E[(X-E(X))(Y-E(Y))]$$

Propm. $\text{cov}(X, Y) = \text{cov}(X, Y)$

$$= E(XY - Y\underline{E(X)} - \underline{XE(Y)} + \underline{E(X) \cdot E(Y)}) = E(XY) - E(X) \cdot E(Y)$$

Príkladom $E(XY)$ je

a) pre diskrétu X, Y

$$E(XY) = \sum_i \sum_j x_i y_j p(x_i, y_j)$$

b) pre spojité X, Y

$$E(XY) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x y f(x, y) dx dy$$

Věta. Jestliže X, Y nezávislé
náhodné veličiny, je
$$\text{cov}(X, Y) = 0.$$

(Překážka, že X, Y jsou nekorelované)

Proč? Nezávislost $X, Y \Rightarrow$

$$E(XY) = E(X) \cdot E(Y)$$

Obráceně: Je-li $\text{cov}(X, Y) \neq 0$, pak
jsou X, Y závislé.

$\text{cov}(X, Y)$ jako míra závislosti X, Y^2
když přem $X \rightarrow 2X, Y \rightarrow 2Y$, tak

$$\text{cov}(2X, 2Y) = 8 \text{cov}(X, Y)$$

ještě ne; j. třeba „normová“.

$$\begin{aligned} \text{cov} \left(\frac{X - E(X)}{\sigma_X}, \frac{Y - E(Y)}{\sigma_Y} \right) &= \\ &= \frac{E[(X - E(X)) \cdot (Y - E(Y))]}{\sigma_X \cdot \sigma_Y} = \frac{\text{cov}(X, Y)}{\sigma_X \cdot \sigma_Y} \end{aligned}$$

Def. $\frac{\text{cov}(X, Y)}{\sigma_X \cdot \sigma_Y} = \rho(X, Y)$

je korelacioni koeficijent X, Y -

Vešta. 1. Za nezavisne var. j. X, Y na (Ω, \mathcal{G}, P) je $\rho(X, Y) = 0$

2. $-1 \leq \rho(X, Y) \leq 1$

3. Je-li $Y = a + bX$, tak je

$$\rho(X, Y) = \begin{cases} 1 & (b > 0) \\ -1 & (b < 0) \end{cases}$$

Záver: korelácia koeficient je
miera lineárnej závislosti.

$$\text{Formula: } \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) = S_{XY}$$

je miera odhadu cov(X, Y).

Odhad korelácie koeficientu

$$\text{je } R = \frac{S_{XY}}{\sqrt{S_X^2 \cdot S_Y^2}} \quad (\text{miera korelácie koef.})$$

Realizace korelačního koef. je

$$r = \frac{\sum_{i=1}^n x_i \cdot y_i - n \cdot \bar{x} \bar{y}}{\sqrt{\sum_{i=1}^n (x_i^2 - n \cdot \bar{x}^2) \sum_{i=1}^n (y_i^2 - n \cdot \bar{y}^2)}}$$

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$\sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - 2 \underbrace{\left(\sum_{i=1}^n x_i \right)}_{n \cdot \bar{x}} \bar{x} + \bar{x}^2 \cdot n$$

Co dál? Kdyžby r bylo „uclé“,
testuje se hypotéza $g(X, Y) = 0$

Platí: $\frac{R}{\sqrt{1-R^2}} \cdot \sqrt{n-2}$ má Studentovo
rozdělení s $n-2$ stupni
volnosti

Lineární regrese

3 metody nejmenších součtů
čtyřech odchytek naměřené
regresní přímky

$$y - E(Y) = \frac{\text{cov}(X, Y)}{D(X)} (x - E(X))$$

průměrně

$$y - \bar{y} = \frac{s_{xy}}{s_x^2} (x - \bar{x})$$

Porudmg:

1.) Zue' regresni' funkce $y = f(x)$

$$s_y^2 = \frac{1}{n} \sum (y_i - \bar{y})^2$$

$$\hat{y}_i = f(x_i)$$

$$s_{\hat{y}}^2 = \frac{1}{n} \sum (\hat{y}_i - \bar{y})^2$$

Vesmeme-li podíl

$$\frac{s_{\hat{\eta}}^2}{s_{\eta}^2} = l_{yx}^2 \quad (\text{index determinace})$$

l_{yx} - index korelace

2. Všechny 'složky' vyjese a korelace

$$\eta = a + b_1 x_1 + b_2 x_2 + \dots$$