

KORRELÁCIÓ-ANALÍZIS

több (két) valószínűségi változó közti kapcsolat vizsgálata

Két valószínűségi változó közti kapcsolat

fiúk
magassága



összefüggő

apák magassága

mennyi idő
alatt tanul meg
az unokaöcs
spanyolul



független

apák magassága

Két valószínűségi változó együttes eloszlása

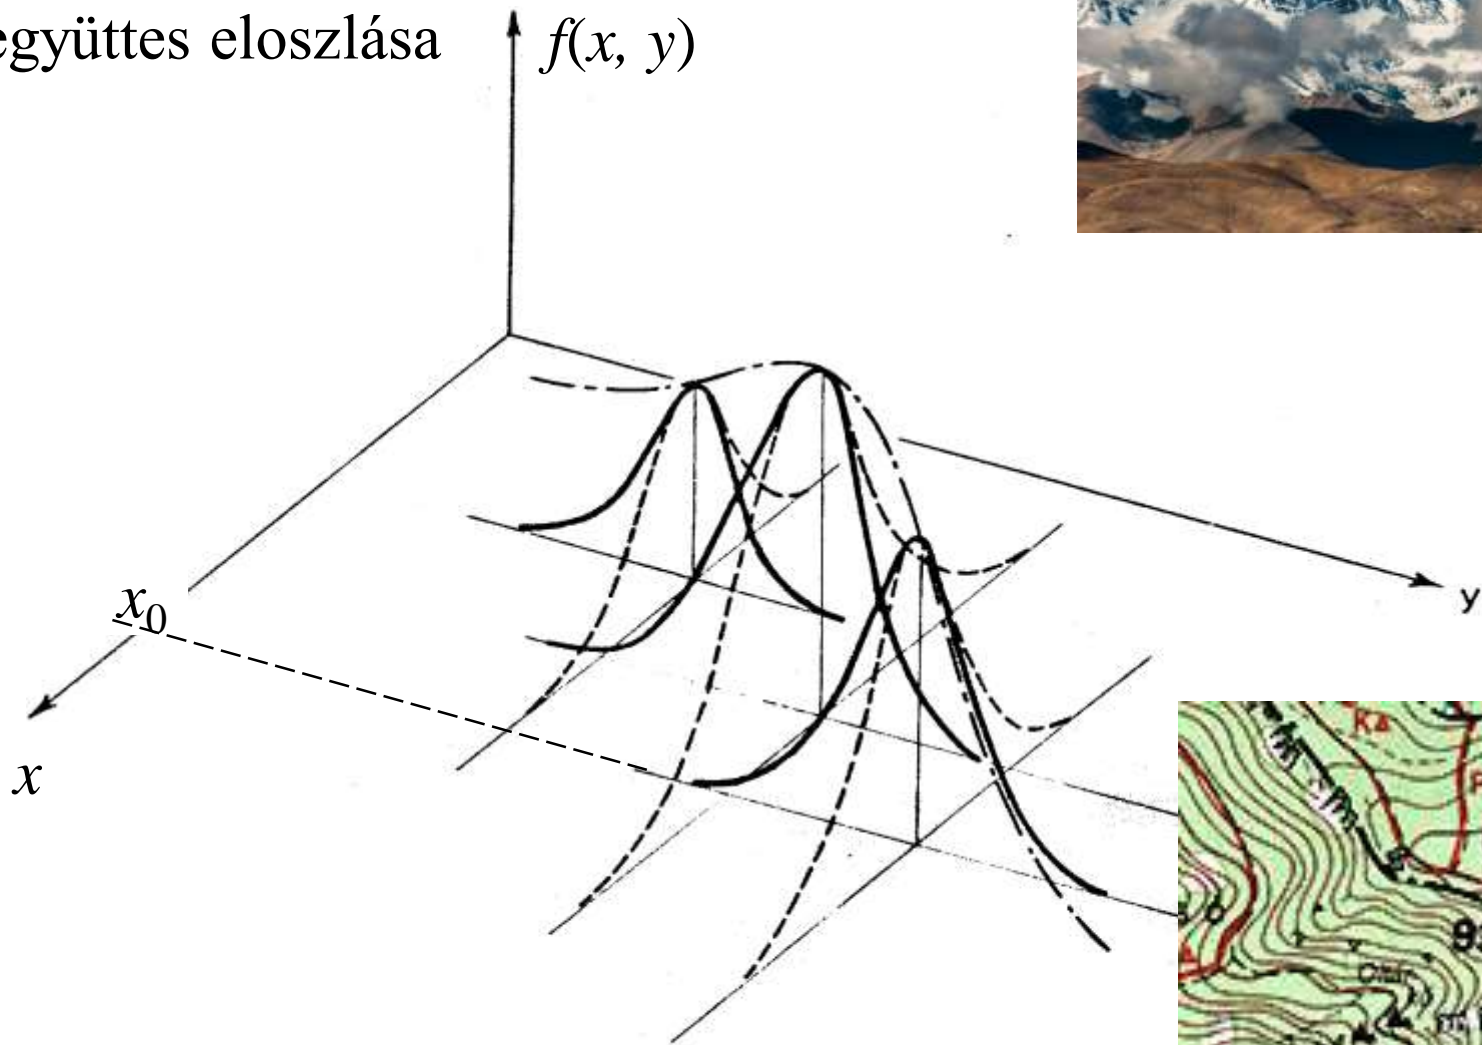
A kétváltozós eloszlás sűrűségfüggvénye:

$$P(x_0 < x \leq x_0 + \Delta x; y_0 < y \leq y_0 + \Delta y) = \\ = \int_{x_0}^{x_0 + \Delta x} \int_{y_0}^{y_0 + \Delta y} f(x, y) dx dy \approx f(x_0, y_0) \Delta x \Delta y$$

És eloszlásfüggvénye:

$$P(x \leq x_0; y \leq y_0) = F(x_0, y_0) = \int_{-\infty}^{x_0} \int_{-\infty}^{y_0} f(x, y) dx dy$$

Két normális eloszlású
valószínűségi változó
együttes eloszlása




Korreláció

Valószínűségi változók függetlensége


Az x és y valószínűségi változók függetlenek, ha

$$f(x, y) = f(x)f(y)$$

A színtvonalas ábrán az ellipszisek főtengelyei párhuzamosak a koordinátatengelyekkel



Szintvonalas ábra nem független valószínűségi változókra



Valószínűségi változók közti kapcsolat jellemzése

Két mutatószám:

- kovariancia
- (Pearson –féle) korrelációs együttható

Kovariancia

Két valószínűségi változó összegének varianciája:

$$\text{Var}(x + y) = E \left\{ [(x + y) - E(x + y)]^2 \right\} = \text{Var}(x) + \text{Var}(y) + 2\text{Cov}(x, y)$$

mert:

$$\begin{aligned} E \left\{ \left[[x - E(x)] + [y - E(y)] \right]^2 \right\} &= E \left\{ [x - E(x)]^2 \right\} + E \left\{ [y - E(y)]^2 \right\} + \\ &+ 2E \left\{ [x - E(x)][y - E(y)] \right\} = \text{Var}(x) + \text{Var}(y) + 2\text{Cov}(x, y) \end{aligned}$$

$$\text{Var}(x) = \sigma_x^2 = E[(x - \mu)^2]$$

$$\text{Cov}(x, y) = \sigma_{xy} = E\{[x - E(x)][y - E(y)]\}$$

Ha x és y függetlenek:

$$\sigma_{xy} = 0$$

$$\text{Var}(x + y) = \text{Var}(x) + \text{Var}(y)$$

Kovariancia mintabeli becslése

$$\text{Cov}(x, y) = \sigma_{xy} = E\{[x - E(x)][y - E(y)]\}$$

$$\sigma_{xy} \text{ becslése: } \hat{\sigma}_{xy} = s_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n-1}$$

$$\text{(emlékeztetőül)} \quad \hat{\sigma}^2 = s^2 = \frac{\sum (x_i - \bar{x})^2}{n-1}$$

Korrelációs együttható

$$\rho_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} = \frac{E[(x - E(x))(y - E(y))]}{\sigma_x \sigma_y}$$

Tulajdonságai:

- léptékfüggetlen
- előjele van
- értéke: $-1 \leq \rho \leq 1$
- a **lineáris** kapcsolat szorosságát méri

Ha x és y függetlenek: $\sigma_{xy} = 0$ $\rho_{xy} = 0$


Mintabeli (becsült) korrelációs együttható

$$\hat{\rho} \equiv r = \frac{s_{xy}}{s_x s_y} = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\left[\sum_i (x_i - \bar{x})^2 \right] \left[\sum_i (y_i - \bar{y})^2 \right]}}$$

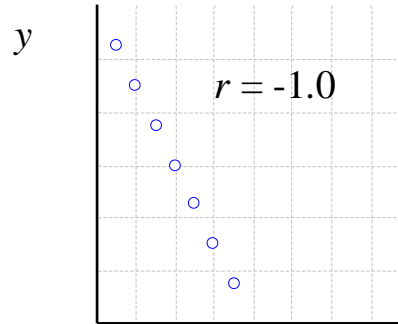
(emlékeztetőül) $\hat{\sigma}^2 = s^2 = \frac{\sum (x_i - \bar{x})^2}{n-1}$

σ_{xy} becslése $\hat{\sigma}_{xy} = s_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{n-1}$


Korreláció két valószínűségi változó között




(a) x




(b) x



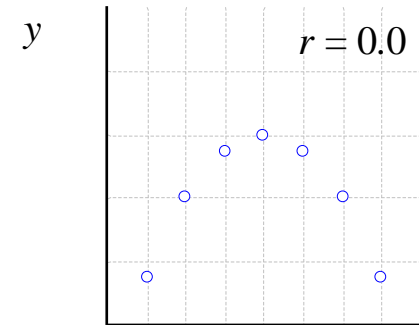
(c) x



(d) x



(e) x

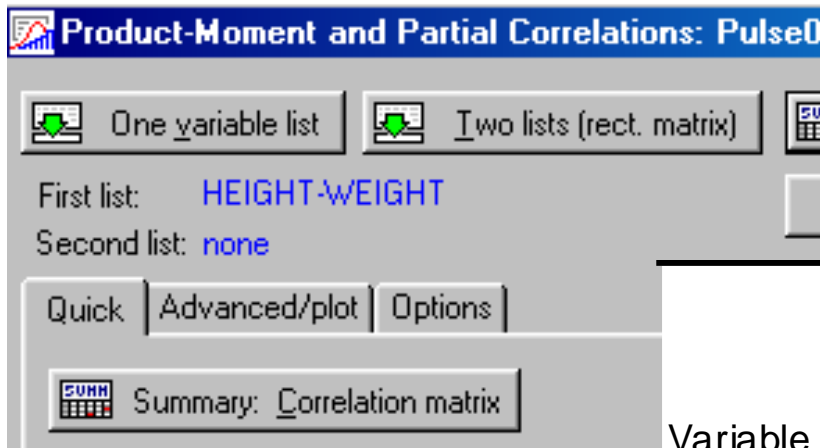


(f) x

Példa:

Számítsuk ki a pulzus-példában a testmagasság és a testsúly közötti korrelációs együtthatót!

(Statistics > Basic Statistics and Tables > Correlation matrices)



Correlations (Pulse0)		
Marked correlations are significant at $p < .0500$		
N=92 (Casewise deletion of missing data)		
Variable	HEIGHT	WEIGHT
HEIGHT	1.00	0.78
WEIGHT	0.78	1.00

A korrelációs együttható szignifikanciájának vizsgálata

$$\text{Ha } \rho=0 \quad t = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2} \quad \nu=n-2$$

DE: A szignifikáns korreláció nem jelent kauzális összefüggést!

Pl. a tűz okozta kár nagysága és az oltásban részt vevő tűzoltók száma

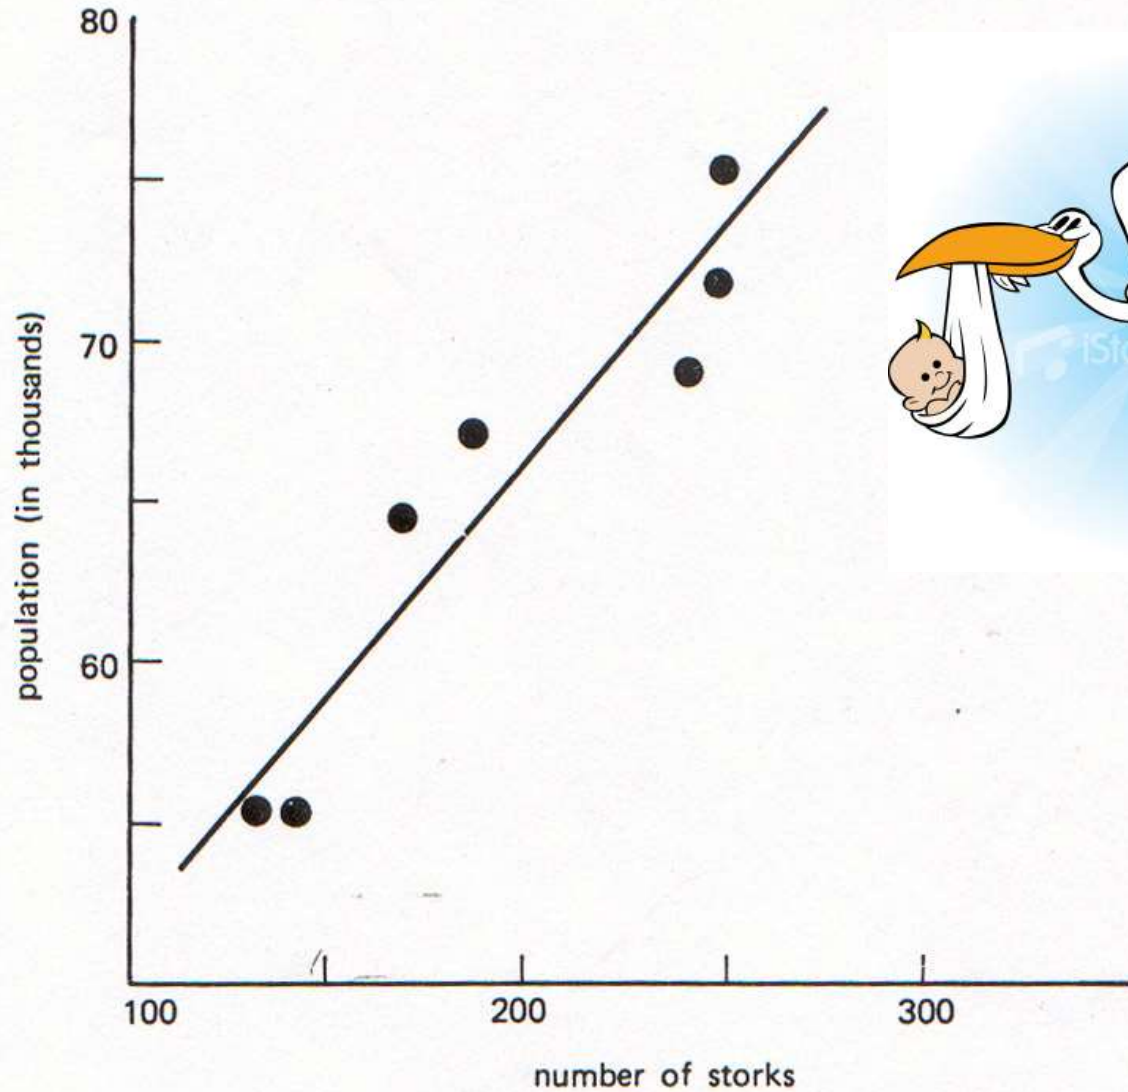


FIGURE 1.4. A plot of the population of Oldenburg at the end of each year against the number of storks observed in that year, 1930–1936.