

## Függetlenség: példa (6. előadás)

Emlékeztető: az  $A$  és  $B$  események **függetlenek**, ha

$$\mathbb{P}(A \cap B) = \mathbb{P}(A) \cdot \mathbb{P}(B).$$

Ha például  $X$  a csapadékmennyiség holnap Budapesten (mm-ben), és  $Y$  New Yorkban, akkor például

$$A : X \leq 5; \quad B : Y \leq 5$$

esetén ez a feltétel így írható:

$$\mathbb{P}(X \leq 5, Y \leq 5) = \mathbb{P}(X \leq 5) \cdot \mathbb{P}(Y \leq 5).$$

Azaz, feltételezve, hogy a két város időjárása egymástól független: annak valószínűsége, hogy **mindkét helyen legfeljebb 5 mm csapadék lesz**, a két esemény **valószínűségének szorzata**.

## Valószínűségi változók függetlensége

- **két valószínűségi változóra:** az  $X, Y : \Omega \rightarrow \mathbb{R}$  valószínűségi változók **függetlenek**, ha

$$\mathbb{P}(X \leq t_1, Y \leq t_2) = \mathbb{P}(X \leq t_1) \cdot \mathbb{P}(Y \leq t_2)$$

teljesül tetszőleges  $t_1, t_2 \in \mathbb{R}$  valós számokra.

- **véges sok valószínűségi változóra:**  $X_1, \dots, X_n : \Omega \rightarrow \mathbb{R}$  valószínűségi változók **függetlenek**, ha

$$\begin{aligned} \mathbb{P}(X_1 \leq t_1, X_2 \leq t_2, \dots, X_n \leq t_n) &= \\ &= \mathbb{P}(X_1 \leq t_1) \cdot \mathbb{P}(X_2 \leq t_2) \dots \mathbb{P}(X_n \leq t_n) \end{aligned}$$

teljesül tetszőleges  $t_1, t_2, \dots, t_n$  valós számokra.

- **megszámlálható sok valószínűségi változóra:** az  $X_1, X_2, X_3 \dots$  valószínűségi változók **függetlenek**, ha közülük bármely véges sokat kiválasztva független valószínűségi változókat kapunk.

## Függetlenség diszkrét esetben

Ha a valószínűségi változók **diszkrét**, azaz lehetséges értékeik halmaza véges vagy megszámlálhatóan végtelen, akkor a függetlenséget az alábbi módon is ellenőrizhetjük.

Az  $X$  és  $Y$  **diszkrét** valószínűségi változók pontosan akkor **függetlenek**, ha az  $X$  minden lehetséges  $x_k$  értékére és az  $Y$  minden lehetséges  $y_l$  értékére teljesül, hogy

$$\mathbb{P}(X = x_k, Y = y_l) = \mathbb{P}(X = x_k) \cdot \mathbb{P}(Y = y_l) \quad (k, l = 1, 2, \dots).$$

Vagyis: annak valószínűsége, hogy  $X$  értéke  $x_k$  és  $Y$  értéke  $y_l$ , ennek a két eseménynek **a valószínűségének a szorzata**.

## Valószínűségi változók függetlensége: példa

Kétszer dobunk egy szabályos dobókockával. Igaz-e, hogy az **első dobott szám** és a **második dobott szám** értéke egymástól független?

## Valószínűségi változók függetlensége: példa

Kétszer dobunk egy szabályos dobókockával. Igaz-e, hogy az **első dobott szám** és a **második dobott szám** értéke egymástól független?

**Tipp.** a második dobásnál az első dobás értéke „elfelejtődik”, nincs kapcsolat a két dobás között  $\Rightarrow$  a két dobott szám **független**.

## Valószínűségi változók függetlensége: példa

Kétszer dobunk egy szabályos dobókockával. Igaz-e, hogy az **első dobott szám** és a **második dobott szám** értéke egymástól független?

**Tipp.** a második dobásnál az első dobás értéke „elfelejtődik”, nincs kapcsolat a két dobás között  $\Rightarrow$  a két dobott szám **független**.

**Indoklás.** Legyen  $X$  az első dobás,  $Y$  a második. Legyen például  $x_k = 3, y_l = 5$ . Ekkor a feltétel teljesül:

$$\frac{1}{36} = \mathbb{P}(X = 3, Y = 5) = \mathbb{P}(X = 3) \cdot \mathbb{P}(Y = 5) = \frac{1}{6} \cdot \frac{1}{6}.$$

## Valószínűségi változók függetlensége: példa

Kétszer dobunk egy szabályos dobókockával. Igaz-e, hogy az **első dobott szám** és a **második dobott szám** értéke egymástól független?

**Tipp.** a második dobásnál az első dobás értéke „elfelejtődik”, nincs kapcsolat a két dobás között  $\Rightarrow$  a két dobott szám **független**.

**Indoklás.** Legyen  $X$  az első dobás,  $Y$  a második. Legyen például  $x_k = 3, y_l = 5$ . Ekkor a feltétel teljesül:

$$\frac{1}{36} = \mathbb{P}(X = 3, Y = 5) = \mathbb{P}(X = 3) \cdot \mathbb{P}(Y = 5) = \frac{1}{6} \cdot \frac{1}{6}.$$

Hasonlóképpen tetszőleges  $(x_k, y_l)$  lehetséges értékekre (azaz 1 és 6 közötti egészekre) igaz, hogy

$$\frac{1}{36} = \mathbb{P}(X = x_k, Y = y_l) = \mathbb{P}(X = x_k) \cdot \mathbb{P}(Y = y_l) = \frac{1}{6} \cdot \frac{1}{6}.$$

Ezért valóban **a két dobás egymástól független**.

## Valószínűségi változók függetlensége: példa

Kétszer dobunk egy szabályos dobókockával. Igaz-e, hogy a dobott számok **összege** és **szorzata** független egymástól?

## Valószínűségi változók függetlensége: példa

Kétszer dobunk egy szabályos dobókockával. Igaz-e, hogy a dobott számok **összege** és **szorzata** független egymástól?

**Tipp:** minél nagyobb az összeg, annál valószínűbb, hogy a szorzat értéke is inkább nagy lesz  $\Rightarrow$  **nem függetlenek**.

**Indoklás:** legyen  $X$  az összeg,  $Y$  a szorzat. Ha például  $X = 2$ : ez csak úgy lehet, hogy mindkét dobás 1-es, vagyis ekkor  $Y$  értéke biztosan 1. Ezért ha például  $x_1 = 2$  és  $y_2 = 2$ -t választunk,  $X = 2$  és  $Y = 2$  egyszerre nem következhetnek be, és így:

$$\begin{aligned} 0 &= \mathbb{P}(X = 2, Y = 2) \neq \mathbb{P}(X = 2) \cdot \mathbb{P}(Y = 2) = \\ &= \mathbb{P}(11) \cdot \mathbb{P}(12 \text{ vagy } 21) = \frac{1}{36} \cdot \frac{1}{18} > 0. \end{aligned}$$

Vagyis az  $x_1 = 2$  és  $y_2 = 2$  párra nem teljesül az előírt feltétel, az **összeg és szorzat nem függetlenek**.

## A várható érték tulajdonságai

- (összeg várható értéke) Ha  $X, Y$  valószínűségi változók, és  $X, Y, X + Y$  várható értéke létezik, akkor

$$\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y).$$

- (konstans kiemelése) Ha az  $X$  valószínűségi változó várható értéke létezik, és  $c$  tetszőleges valós szám, akkor

$$\mathbb{E}(c \cdot X) = c \cdot \mathbb{E}(X).$$

## A várható érték tulajdonságai

- (összeg várható értéke) Ha  $X, Y$  valószínűségi változók, és  $X, Y, X + Y$  várható értéke létezik, akkor

$$\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y).$$

- (konstans kiemelése) Ha az  $X$  valószínűségi változó várható értéke létezik, és  $c$  tetszőleges valós szám, akkor

$$\mathbb{E}(c \cdot X) = c \cdot \mathbb{E}(X).$$

- (szorzat várható értéke független esetben) Ha az  $X$  és  $Y$  valószínűségi változók **függetlenek**, és  $X, Y, X \cdot Y$  várható értéke létezik, akkor

$$\mathbb{E}(XY) = \mathbb{E}(X) \cdot \mathbb{E}(Y).$$

## A várható érték tulajdonságai

- (összeg várható értéke) Ha  $X, Y$  valószínűségi változók, és  $X, Y, X + Y$  várható értéke létezik, akkor

$$\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y).$$

- (konstans kiemelése) Ha az  $X$  valószínűségi változó várható értéke létezik, és  $c$  tetszőleges valós szám, akkor

$$\mathbb{E}(c \cdot X) = c \cdot \mathbb{E}(X).$$

- (szorzat várható értéke független esetben) Ha az  $X$  és  $Y$  valószínűségi változók **függetlenek**, és  $X, Y, X \cdot Y$  várható értéke létezik, akkor

$$\mathbb{E}(XY) = \mathbb{E}(X) \cdot \mathbb{E}(Y).$$

- (függvény várható értéke) Ha  $g : \mathbb{R} \rightarrow \mathbb{R}$  olyan függvény, hogy  $\mathbb{E}(X)$  létezik, és az  $X$  lehetséges értékei  $x_1, x_2, \dots$ , akkor

$$\mathbb{E}(g(X)) = \sum_{i=1}^{\infty} g(x_i) \mathbb{P}(X = x_i).$$

## Összeg várható értéke

### Állítás

Ha  $X, Y$  valószínűségi változók, és  $X, Y, X + Y$  várható értéke létezik, akkor

$$\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y).$$

*Bizonyítás.* Legyenek  $X$  lehetséges értékei  $x_1, x_2, \dots$ , az  $Y$  lehetséges értékei  $y_1, y_2, \dots$ . Ekkor az  $X + Y$  lehetséges értékei  $x_k + y_m$  alakúak, és

$$\begin{aligned}\mathbb{E}(X + Y) &= \sum_{k,m} (x_k + y_m) \mathbb{P}(X = x_k, Y = y_m) = \\ &= \sum_{k,m} x_k \mathbb{P}(X = x_k, Y = y_m) + \sum_{k,m} y_m \mathbb{P}(X = x_k, Y = y_m) = \\ &= \sum_k x_k \mathbb{P}(X = x_k) + \sum_m y_m \mathbb{P}(Y = y_m) = \mathbb{E}(X) + \mathbb{E}(Y),\end{aligned}$$

ahol azt használtuk, hogy az  $\{X = x_k, Y = y_m\}$  események kizáróak, uniójuk  $\{X = x_k\}$ , és hasonlóképpen a másik tagban az  $Y$  esetén.

## Összeg várható értéke

### Állítás

Ha  $X, Y$  valószínűségi változók, és  $X, Y, X + Y$  várható értéke létezik, akkor

$$\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y).$$

*Bizonyítás.* Legyenek  $X$  lehetséges értékei  $x_1, x_2, \dots$ , az  $Y$  lehetséges értékei  $y_1, y_2, \dots$ . Ekkor az  $X + Y$  lehetséges értékei  $x_k + y_m$  alakúak, és

$$\begin{aligned}\mathbb{E}(X + Y) &= \sum_{k,m} (x_k + y_m) \mathbb{P}(X = x_k, Y = y_m) = \\ &= \sum_{k,m} x_k \mathbb{P}(X = x_k, Y = y_m) + \sum_{k,m} y_m \mathbb{P}(X = x_k, Y = y_m) = \\ &= \sum_k x_k \mathbb{P}(X = x_k) + \sum_m y_m \mathbb{P}(Y = y_m) = \mathbb{E}(X) + \mathbb{E}(Y),\end{aligned}$$

ahol azt használtuk, hogy az  $\{X = x_k, Y = y_m\}$  események kizáróak, uniójuk  $\{X = x_k\}$ , és hasonlóképpen a másik tagban az  $Y$  esetén.

*Következmény:*  $\mathbb{E}(X_1 + X_2 + \dots + X_n) = \mathbb{E}(X_1) + \mathbb{E}(X_2) + \dots + \mathbb{E}(X_n)$ .

## Szorzat várható értéke független esetben

### Állítás

Ha  $X, Y$  **független** valószínűségi változók, és  $X, Y$  várható értéke létezik, akkor

$$\mathbb{E}(XY) = \mathbb{E}(X)\mathbb{E}(Y).$$

*Bizonyítás.* Legyenek  $X$  lehetséges értékei  $x_1, x_2, \dots$ , az  $Y$  lehetséges értékei  $y_1, y_2, \dots$ . Ekkor az  $X + Y$  lehetséges értékei  $x_k + y_m$  alakúak, és

$$\begin{aligned}\mathbb{E}(XY) &= \sum_{k,m} x_k \cdot y_m \mathbb{P}(X = x_k, Y = y_m) = \\ &\stackrel{(*)}{=} \sum_{k,m} x_k y_m \mathbb{P}(X = x_k) \cdot \mathbb{P}(Y = y_m) \\ &= \left( \sum_k x_k \mathbb{P}(X = x_k) \right) \cdot \left( \sum_m y_m \mathbb{P}(Y = y_m) \right) = \mathbb{E}(X) \cdot \mathbb{E}(Y),\end{aligned}$$

ahol a (\*) lépésben használtuk a függetlenségnek a diszkrét valószínűségi változókra vonatkozó alakját.

## A szórásnégyzet tulajdonságai

- (nemnegativitás)  $D^2(X) \geq 0$  és  $D(X) \geq 0$  mindig teljesül
- (szorzás és eltolás) ha  $a, b$  valós számok,  $X$  véges szórású valószínűségi változó, akkor

$$D^2(aX + b) = a^2 D^2(X) \quad \Rightarrow \quad D(aX + b) = |a| D(X).$$

## A szórásnégyzet tulajdonságai

- (nemnegativitás)  $D^2(X) \geq 0$  és  $D(X) \geq 0$  mindig teljesül
- (szorzás és eltolás) ha  $a, b$  valós számok,  $X$  véges szórású valószínűségi változó, akkor

$$D^2(aX + b) = a^2 D^2(X) \quad \Rightarrow \quad D(aX + b) = |a| D(X).$$

- (összeg szórása független esetben) ha az  $X, Y$  valószínűségi változók **függetlenek** és szórásuk létezik, akkor

$$D^2(X+Y) = D^2(X) + D^2(Y) \quad \Rightarrow \quad D(X+Y) = \sqrt{D^2(X) + D^2(Y)}.$$

- van olyan valószínűségi változó, melynek várható értéke véges, de a szórása nem létezik (például:  $\mathbb{P}(X = k) = c/k^3$  megfelelő  $c$ -vel)

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) = \mathbb{E}(X) - \mathbb{E}(Y) = -2$ ;
- $\mathbb{E}(2X + 3Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) = \mathbb{E}(X) - \mathbb{E}(Y) = -2$ ;
- $\mathbb{E}(2X + 3Y) = 2\mathbb{E}(X) + 3\mathbb{E}(Y) = 2 \cdot 4 + 3 \cdot 6 = 26$ ;
- $\mathbb{E}(2X - 3Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) = \mathbb{E}(X) - \mathbb{E}(Y) = -2$ ;
- $\mathbb{E}(2X + 3Y) = 2\mathbb{E}(X) + 3\mathbb{E}(Y) = 2 \cdot 4 + 3 \cdot 6 = 26$ ;
- $\mathbb{E}(2X - 3Y) = 2\mathbb{E}(X) - 3\mathbb{E}(Y) = 2 \cdot 4 - 3 \cdot 6 = -10$ ;
- $D(X + Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) = \mathbb{E}(X) - \mathbb{E}(Y) = -2$ ;
- $\mathbb{E}(2X + 3Y) = 2\mathbb{E}(X) + 3\mathbb{E}(Y) = 2 \cdot 4 + 3 \cdot 6 = 26$ ;
- $\mathbb{E}(2X - 3Y) = 2\mathbb{E}(X) - 3\mathbb{E}(Y) = 2 \cdot 4 - 3 \cdot 6 = -10$ ;
- $D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{1 + 2^2} = \sqrt{5}$ ;
- $D(X - Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) = \mathbb{E}(X) - \mathbb{E}(Y) = -2$ ;
- $\mathbb{E}(2X + 3Y) = 2\mathbb{E}(X) + 3\mathbb{E}(Y) = 2 \cdot 4 + 3 \cdot 6 = 26$ ;
- $\mathbb{E}(2X - 3Y) = 2\mathbb{E}(X) - 3\mathbb{E}(Y) = 2 \cdot 4 - 3 \cdot 6 = -10$ ;
- $D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{1 + 2^2} = \sqrt{5}$ ;
- $D(X - Y) = \sqrt{D^2(X) + (-1)^2 D^2(Y)} = \sqrt{1 + 2^2} = \sqrt{5}$ ;
- $D(2X + 3Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) = \mathbb{E}(X) - \mathbb{E}(Y) = -2$ ;
- $\mathbb{E}(2X + 3Y) = 2\mathbb{E}(X) + 3\mathbb{E}(Y) = 2 \cdot 4 + 3 \cdot 6 = 26$ ;
- $\mathbb{E}(2X - 3Y) = 2\mathbb{E}(X) - 3\mathbb{E}(Y) = 2 \cdot 4 - 3 \cdot 6 = -10$ ;
- $D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{1 + 2^2} = \sqrt{5}$ ;
- $D(X - Y) = \sqrt{D^2(X) + (-1)^2 D^2(Y)} = \sqrt{1 + 2^2} = \sqrt{5}$ ;
- $D(2X + 3Y) = \sqrt{2^2 D^2(X) + 3^2 D^2(Y)} = \sqrt{4 \cdot 1 + 9 \cdot 4} = \sqrt{40}$ ;
- $D(2X - 3Y) =$

## A várható érték és szórás kiszámítása

**Példa.** Legyen  $X$  olyan valószínűségi változó, melynek várható értéke 4, szórása 1, az  $Y$  valószínűségi változó várható értéke 6, szórása pedig 2. Tegyük fel továbbá, hogy  $X$  és  $Y$  **függetlenek**. Ekkor

- $\mathbb{E}(X + Y) = \mathbb{E}(X) + \mathbb{E}(Y) = 10$ ;
- $\mathbb{E}(X - Y) = \mathbb{E}(X) - \mathbb{E}(Y) = -2$ ;
- $\mathbb{E}(2X + 3Y) = 2\mathbb{E}(X) + 3\mathbb{E}(Y) = 2 \cdot 4 + 3 \cdot 6 = 26$ ;
- $\mathbb{E}(2X - 3Y) = 2\mathbb{E}(X) - 3\mathbb{E}(Y) = 2 \cdot 4 - 3 \cdot 6 = -10$ ;
- $D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{1 + 2^2} = \sqrt{5}$ ;
- $D(X - Y) = \sqrt{D^2(X) + (-1)^2 D^2(Y)} = \sqrt{1 + 2^2} = \sqrt{5}$ ;
- $D(2X + 3Y) = \sqrt{2^2 D^2(X) + 3^2 D^2(Y)} = \sqrt{4 \cdot 1 + 9 \cdot 4} = \sqrt{40}$ ;
- $D(2X - 3Y) = \sqrt{2^2 D^2(X) + (-3)^2 D^2(Y)} = \sqrt{4 \cdot 1 + 9 \cdot 4} = \sqrt{40}$ .

## A binomiális eloszlás várható értéke és szórása

### Állítás

Ha az  $X$  valószínűségi változó binomiális eloszlású  $n$  renddel és  $p$  paraméterrel, azaz

$$\mathbb{P}(X = k) = \binom{n}{k} p^k (1 - p)^{n-k} \quad (k = 0, 1, \dots, n),$$

akkor

$$\mathbb{E}(X) = np; \quad D(X) = \sqrt{np(1 - p)}.$$

**Példa.** Egy kérdőív egy kérdésére  $n = 1000$  megkérdezett közül mindenki a többiektől függetlenül  $p = 0,65$  valószínűséggel válaszol. Ekkor a válaszadók számának (melyet jelöljünk  $X$ -szel) a várható értéke:

$$\mathbb{E}(X) = np = 1000 \cdot 0,65 = 650,$$

míg a szórása:

$$D(X) = \sqrt{np(1 - p)} = \sqrt{1000 \cdot 0,65 \cdot 0,35} = 15,08.$$

## A binomiális eloszlás várható értéke és szórása

*Bizonyítás.* Legyen  $X$  binomiális eloszlású  $n$  renddel és  $p$  paraméterrel. Azaz:  $n$  független kísérletet végzünk, mindegyik  $p$  valószínűséggel sikerül,  $X$  a sikeresek száma. Vezessük be az alábbi indikátorokat  $j = 1, 2, \dots, n$  esetén:

$$X_j = \begin{cases} 1 & \text{ha a } j. \text{ kísérlet sikeres;} \\ 0 & \text{ha a } j. \text{ kísérlet nem sikeres.} \end{cases}$$

Ekkor  $X$  éppen az indikátorok összege (az egyesek száma):

$$X = X_1 + X_2 + \dots + X_n = \sum_{j=1}^n X_j.$$

## A binomiális eloszlás várható értéke és szórása

*Bizonyítás.* Legyen  $X$  binomiális eloszlású  $n$  renddel és  $p$  paraméterrel. Azaz:  $n$  független kísérletet végzünk, mindegyik  $p$  valószínűséggel sikerül,  $X$  a sikeresek száma. Vezessük be az alábbi indikátorokat  $j = 1, 2, \dots, n$  esetén:

$$X_j = \begin{cases} 1 & \text{ha a } j. \text{ kísérlet sikeres;} \\ 0 & \text{ha a } j. \text{ kísérlet nem sikeres.} \end{cases}$$

Ekkor  $X$  éppen az indikátorok összege (az egyesek száma):

$$X = X_1 + X_2 + \dots + X_n = \sum_{j=1}^n X_j.$$

Mivel minden  $j$ -re

$$\mathbb{E}(X_j) = 1 \cdot \mathbb{P}(X = 1) + 0 \cdot \mathbb{P}(X = 0) = p,$$

ezért

$$\begin{aligned} \mathbb{E}(X) &= \mathbb{E}(X_1 + X_2 + \dots + X_n) = \mathbb{E}(X_1) + \mathbb{E}(X_2) + \dots + \mathbb{E}(X_n) = \\ &= p + p + \dots + p = np. \end{aligned}$$

## A binomiális eloszlás várható értéke és szórása

*Bizonyítás.* Ugyanazokat az indikátorokat használjuk:

$$X_j = \begin{cases} 1 & \text{ha a } j.\text{kísérlet sikeres;} \\ 0 & \text{ha a } j.\text{kísérlet nem sikeres.} \end{cases}$$

## A binomiális eloszlás várható értéke és szórása

*Bizonyítás.* Ugyanazokat az indikátorokat használjuk:

$$X_j = \begin{cases} 1 & \text{ha a } j.\text{kísérlet sikeres;} \\ 0 & \text{ha a } j.\text{kísérlet nem sikeres.} \end{cases}$$

Most  $X_j = X_j^2$ , hiszen  $0^2 = 0$  és  $1^2 = 1$ , és már láttuk, hogy  $\mathbb{E}(X_j) = p$ .  
Ezért

$$D^2(X_j) = \mathbb{E}(X_j^2) - \mathbb{E}(X_j)^2 = \mathbb{E}(X_j) - \mathbb{E}(X_j)^2 = p - p^2 = p(1 - p),$$

Mivel az  $X_j$  indikátorok **függetlenek**, és az összegük  $X$ :


$$\begin{aligned} D(X) &= \sqrt{D^2(X_1 + X_2 + \dots + X_n)} = \sqrt{D^2(X_1) + D^2(X_2) + \dots + D^2(X_n)} = \\ &= \sqrt{p(1 - p) + p(1 - p) + \dots + p(1 - p)} = \sqrt{np(1 - p)}. \end{aligned}$$

A hipergeometrikus eloszlás várható értékére vonatkozó összefüggés szintén indikátorokkal igazolható.

# Kovariancia és korrelációs együttható

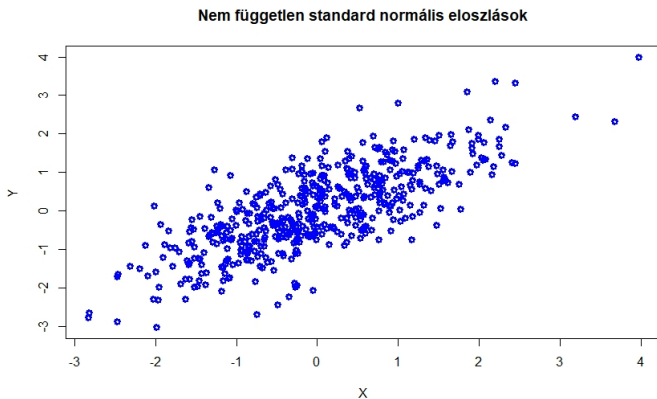
- két valószínűségi változó lehet
  - ▶ **független**: például két találmásra választott ember jövedelme, vagy,
  - ▶ **nem független**: például egy találmásra választott ember jövedelme most, illetve fél év múlva
- az **összefüggőség mértéke** különböző lehet:
  - ▶ egy találmásra választott felnőtt életkora és jövedelme „erősen összefüggő”, a fiataloké és időseké általában alacsonyabb;
  - ▶ egy találmásra választott felnőtt életkora és testmagassága „gyengén összefüggő”, hiszen egy fiatal felnőtt nőhet, az idősek pedig valamennyit veszítenek a testmagasságukból, de egyik változás sem nagyon jelentős.
- a kapcsolat erősségének jellemzésére többféle mérőszám használható, ezek között van a **kovariancia** és a **korrelációs együttható**. Ez utóbbinak a „nagy” értékei „erős, lineáris jellegű” összefüggésre utalnak.

# Független normális eloszlások



500 darab véletlen pont a síkon, melyek koordinátái **független** standard normális eloszlásúak. A koordináták között nincs kapcsolat: a kovariancia és a korrelációs együttható is **0** lesz.


# Pozitív korreláció



500 elemű minta a következő többdimenziós normális eloszlásból:  $(X, \frac{X+Z}{\sqrt{2}})$ , ahol  $X, Z \sim N(0, 1)$  függetlenek.

Minél nagyobb  $X$ , „valószínűleg” annál nagyobb  $(X + Z)/\sqrt{2}$  is  $\rightarrow$  ennek megfelelően a két koordináta közötti **kovariancia** és **korrelációs együttható** is **pozitív** lesz.

## Erős pozitív korreláció



100 elemű minta az  $(X+Y, 300X+400Y)$  eloszlásból, ahol  $X \sim \text{Poisson}(100)$  és  $Y \sim \text{Poisson}(180)$  függetlenek. A megfigyelések szinte teljesen egy pozitív meredekségű egyenesre illeszkednek  $\rightarrow$  a **korrelációs együttható pozitív és majdnem 1**, ami „nagy”, mert ennek 1 lesz a lehetséges legnagyobb értéke.

## A kovariancia

Legyenek  $X$  és  $Y$  olyan valószínűségi változók, melyeknek szórása létezik. Ekkor  $X$  és  $Y$  **kovarianciája**:

$$\text{cov}(X, Y) = \mathbb{E}((X - \mathbb{E}(X)) \cdot (Y - \mathbb{E}(Y))).$$

# A kovariancia

Legyenek  $X$  és  $Y$  olyan valószínűségi változók, melyeknek szórása létezik. Ekkor  $X$  és  $Y$  **kovarianciája**:

$$\text{cov}(X, Y) = \mathbb{E}((X - \mathbb{E}(X)) \cdot (Y - \mathbb{E}(Y))).$$

- **A kovariancia kiszámítása:**

$$\text{cov}(X, Y) = \mathbb{E}(X \cdot Y) - \mathbb{E}(X)\mathbb{E}(Y).$$

- **Szimmetria.**  $\text{cov}(X, Y) = \text{cov}(Y, X)$ .
- **Kapcsolat a szórásnégyzettel.**  $\text{cov}(X, X) = D^2(X)$ .

# A kovariancia

Legyenek  $X$  és  $Y$  olyan valószínűségi változók, melyeknek szórása létezik. Ekkor  $X$  és  $Y$  **kovarianciája**:

$$\text{cov}(X, Y) = \mathbb{E}((X - \mathbb{E}(X)) \cdot (Y - \mathbb{E}(Y))).$$

- **A kovariancia kiszámítása:**

$$\text{cov}(X, Y) = \mathbb{E}(X \cdot Y) - \mathbb{E}(X)\mathbb{E}(Y).$$

- **Szimmetria.**  $\text{cov}(X, Y) = \text{cov}(Y, X)$ .
- **Kapcsolat a szórásnégyzettel.**  $\text{cov}(X, X) = D^2(X)$ .
- **Függetlenséggel való kapcsolat.** Ha az  $X$  és  $Y$  valószínűségi változók **függetlenek**, akkor  $\text{cov}(X, Y) = 0$ .

**Fordítva nem igaz:**  $\text{cov}(X, Y) = 0$  esetén nem biztos, hogy  $X$  és  $Y$  függetlenek.

## A kovariancia tulajdonságai

- Konstanssal való kovariancia.  $\text{cov}(X, c) = 0$ , ha  $c$  valós szám.
- **Linearitás.** Egyrészt

$$\text{cov}(X + Y, Z) = \text{cov}(X, Z) + \text{cov}(Y, Z),$$

másrészt tetszőleges  $c \in \mathbb{R}$  valós számra

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

- **Összeg szórásnégyzete.**  $D^2(X + Y) = D^2(X) + D^2(Y) + 2\text{cov}(X, Y)$ .  
Továbbá

$$D^2\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n D^2(X_i) + 2 \sum_{i < j} \text{cov}(X_i, X_j).$$

- Különbség szórásnégyzete.  $D^2(X - Y) = D^2(X) + D^2(Y) - 2\text{cov}(X, Y)$ .

## Kovariancia: példa

Egy üzletben az  $A$  és  $B$  újság forgalmát figyelik.

- Az  $A$  újságból egy nap alatt eladott példányok száma  $X$ ;
- a  $B$  újságból eladott példányok száma  $Y$ .
- Tegyük fel, hogy  $X$  és  $Y$  **függetlenek**, **Poisson-eloszlásúak**,  $X$  paramétere 100,  $Y$ -é 180.
- Az  $A$  újság ára 300 forint, a  $B$ -é 400.

Mennyi az összesen **eladott példányok számának** és az ezekből származó **bevételnek** a kovarianciája?

## Kovariancia: példa

Egy üzletben az  $A$  és  $B$  újság forgalmát figyelik.

- Az  $A$  újságból egy nap alatt eladott példányok száma  $X$ ;
- a  $B$  újságból eladott példányok száma  $Y$ .
- Tegyük fel, hogy  $X$  és  $Y$  **függetlenek**, **Poisson-eloszlásúak**,  $X$  paramétere 100,  $Y$ -é 180.
- Az  $A$  újság ára 300 forint, a  $B$ -é 400.

Mennyi az összesen **eladott példányok számának** és az ezekből származó **bevételnek** a kovarianciája? Azaz mennyi  $\text{cov}(X + Y, 300X + 400Y)$ ?

A számolás előtt: **pozitív**, **negatív** vagy **0** kovarianciára tippelnénk?

## Kovariancia: példa

Egy üzletben az  $A$  és  $B$  újság forgalmát figyelik.

- Az  $A$  újságból egy nap alatt eladott példányok száma  $X$ ;
- a  $B$  újságból eladott példányok száma  $Y$ .
- Tegyük fel, hogy  $X$  és  $Y$  **függetlenek**, **Poisson-eloszlásúak**,  $X$  paramétere 100,  $Y$ -é 180.
- Az  $A$  újság ára 300 forint, a  $B$ -é 400.

Mennyi az összesen **eladott példányok számának** és az ezekből származó **bevételnek** a kovarianciája? Azaz mennyi  $\text{cov}(X + Y, 300X + 400Y)$ ?

A számolás előtt: **pozitív**, **negatív** vagy **0** kovarianciára tippelnénk?

Mivel **minél nagyobb** a példányszám, „**valószínűleg**” **annál nagyobb a bevétel**, **pozitív** kovarianciára számíthatunk.

## Kovariancia: példa

$X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100, az  $Y$ -é 180. Ekkor az eladott példányok számának és a bevételnek a kovarianciája:

$$\begin{aligned}\operatorname{cov}(X + Y, 300X + 400Y) &\stackrel{(a)}{=} \operatorname{cov}(X, 300X) + \operatorname{cov}(X, 400Y) + \\ &\quad + \operatorname{cov}(Y, 300X) + \operatorname{cov}(Y, 400Y) = \\ &\stackrel{(a,b)}{=} 300 \cdot \operatorname{cov}(X, X) + 400 \cdot \operatorname{cov}(Y, Y) = \\ &\stackrel{(b)}{=} 300D^2(X) + 400D^2(Y) = \\ &\stackrel{(c)}{=} 300 \cdot 100 + 400 \cdot 180 = 102000,\end{aligned}$$

ahol felhasználtuk, hogy

## Kovariancia: példa

$X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100, az  $Y$ -é 180. Ekkor az eladott példányok számának és a bevételnek a kovarianciája:

$$\begin{aligned}\operatorname{cov}(X + Y, 300X + 400Y) &\stackrel{(a)}{=} \operatorname{cov}(X, 300X) + \operatorname{cov}(X, 400Y) + \\ &\quad + \operatorname{cov}(Y, 300X) + \operatorname{cov}(Y, 400Y) = \\ &\stackrel{(a,b)}{=} 300 \cdot \operatorname{cov}(X, X) + 400 \cdot \operatorname{cov}(Y, Y) = \\ &\stackrel{(b)}{=} 300D^2(X) + 400D^2(Y) = \\ &\stackrel{(c)}{=} 300 \cdot 100 + 400 \cdot 180 = 102000,\end{aligned}$$

ahol felhasználtuk, hogy (a) a kovariancia **lineáris**;

## Kovariancia: példa

$X$  és  $Y$  **függetlenek**, **Poisson-eloszlásúak**,  $X$  paramétere 100, az  $Y$ -é 180. Ekkor az **eladott példányok számának** és a **bevételnek** a kovarianciája:

$$\begin{aligned}\operatorname{cov}(X + Y, 300X + 400Y) &\stackrel{(a)}{=} \operatorname{cov}(X, 300X) + \operatorname{cov}(X, 400Y) + \\ &\quad + \operatorname{cov}(Y, 300X) + \operatorname{cov}(Y, 400Y) = \\ &\stackrel{(a,b)}{=} 300 \cdot \operatorname{cov}(X, X) + 400 \cdot \operatorname{cov}(Y, Y) = \\ &\stackrel{(b)}{=} 300D^2(X) + 400D^2(Y) = \\ &\stackrel{(c)}{=} 300 \cdot 100 + 400 \cdot 180 = 102000,\end{aligned}$$

ahol felhasználtuk, hogy (a) a kovariancia **lineáris**;

(b) **független** valószínűségi változók kovarianciája **0**, illetve egy valószínűségi változó saját magával vett kovarianciája a szórásnégyzete;

## Kovariancia: példa

$X$  és  $Y$  **függetlenek**, **Poisson-eloszlásúak**,  $X$  paramétere 100, az  $Y$ -é 180. Ekkor az **eladott példányok számának** és a **bevételnek** a kovarianciája:


$$\begin{aligned}\text{cov}(X + Y, 300X + 400Y) &\stackrel{(a)}{=} \text{cov}(X, 300X) + \text{cov}(X, 400Y) + \\ &\quad + \text{cov}(Y, 300X) + \text{cov}(Y, 400Y) = \\ &\stackrel{(a,b)}{=} 300 \cdot \text{cov}(X, X) + 400 \cdot \text{cov}(Y, Y) = \\ &\stackrel{(b)}{=} 300D^2(X) + 400D^2(Y) = \\ &\stackrel{(c)}{=} 300 \cdot 100 + 400 \cdot 180 = 102000,\end{aligned}$$

ahol felhasználtuk, hogy (a) a kovariancia **lineáris**;

(b) **független** valószínűségi változók kovarianciája **0**, illetve egy valószínűségi változó saját magával vett kovarianciája a szórásnégyzete;

(c) egy  $\lambda$  paraméterű **Poisson-eloszlású** valószínűségi változó **szórásnégyzete**  $\lambda$ .

## Kovariancia: példa



A bevétel ( $300X + 400Y$ ) és az eladott példányszám ( $X + Y$ ) együttes előfordulása  $n = 100$  független megfigyelésből. Kovariancia:  $\text{cov}(X + Y, 300X + 400Y) = 102000$ .

## Korrelációs együttható: bevezetés

- A **kovariancia** bevezetésének célja, hogy két valószínűségi változó közötti **összefüggés erősségét** tudjuk mérni.
- A korábbi példában: a példányszám és a bevétel kovarianciája **102000** volt.
- Viszont ha a bevételt nem forintban, hanem ezer forintos egységben mérjük:

$X$  : példányszám    $Y$  : bevétel forintban    $Z$  : bevétel ezer forintban,

akkor

$$\text{cov}(X, Z) = \text{cov}\left(X, \frac{Y}{1000}\right) = \frac{\text{cov}(X, Y)}{1000} = 102.$$

Vagyis a kovariancia a **mértékegységtől függ**  $\Rightarrow$  hasznos egy olyan mennyiség, ami szintén az összefüggés erősségét méri, de a mértékegység választásától függetlenül.

- Ilyen lesz a **korrelációs együttható**.

## Korrelációs együttható: definíció

Legyenek  $X$  és  $Y$  olyan valószínűségi változók, melyek szórásnégyzete létezik. Ekkor  $X$  és  $Y$  **korrelációs együtthatója**:

$$R(X, Y) = \begin{cases} \frac{\text{cov}(X, Y)}{D(X)D(Y)}, & \text{ha } D(X) > 0, D(Y) > 0; \\ 0, & \text{ha } D(X) = 0 \text{ vagy } D(Y) = 0. \end{cases}$$

## Korrelációs együttható: definíció

Legyenek  $X$  és  $Y$  olyan valószínűségi változók, melyek szórásnégyzete létezik. Ekkor  $X$  és  $Y$  **korrelációs együtthatója**:

$$R(X, Y) = \begin{cases} \frac{\text{cov}(X, Y)}{D(X)D(Y)}, & \text{ha } D(X) > 0, D(Y) > 0; \\ 0, & \text{ha } D(X) = 0 \text{ vagy } D(Y) = 0. \end{cases}$$

- **Lehetséges értékek.** A korrelációs együttható értéke mindig  $-1$  és  $1$  közé esik:

$$|R(X, Y)| \leq 1.$$

- **Lineáris összefüggés.** Legyen  $a > 0$  valós szám,  $b$  tetszőleges valós szám. Ekkor

$$R(X, aX + b) = 1 \quad \text{és} \quad R(X, -aX + b) = -1.$$

- Tegyük fel, hogy  $|R(X, Y)| = 1$ . Ekkor léteznek olyan  $a$  és  $b$  valós számok, hogy az  $Y = aX + b$  egyenlet  $1$  valószínűséggel teljesül. Vagyis a korrelációs együttható lehetséges legnagyobb értékei lineáris összefüggés esetén érhetők el.

## Korrelációs együttható: példa

Egy üzletben az  $A$  és  $B$  újság forgalmát figyelik.

- Az  $A$  újságból egy nap alatt eladott példányok száma  $X$ ;
- a  $B$  újságból eladott példányok száma  $Y$ .
- Tegyük fel, hogy  $X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100,  $Y$ -é 180.
- Az  $A$  újság ára 300 forint, a  $B$ -é 400.

Mennyi az összesen **eladott példányok számának** és az ezekből származó **bevételnek** a korrelációs együtthatója?

## Korrelációs együttható: példa

Egy üzletben az  $A$  és  $B$  újság forgalmát figyelik.

- Az  $A$  újságból egy nap alatt eladott példányok száma  $X$ ;
- a  $B$  újságból eladott példányok száma  $Y$ .
- Tegyük fel, hogy  $X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100,  $Y$ -é 180.
- Az  $A$  újság ára 300 forint, a  $B$ -é 400.

Mennyi az összesen **eladott példányok számának** és az ezekből származó **bevételnek** a korrelációs együtthatója?

$$\begin{aligned} R(X + Y, 300X + 400Y) &= \frac{\text{cov}(X + Y, 300X + 400Y)}{D(X + Y)D(300X + 400Y)} = \\ &= \frac{102000}{D(X + Y)D(300X + 400Y)} \end{aligned}$$

a korábbi számolás alapján, így a szórásokat kell meghatározni.

## Korrelációs együttható: példa

$X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100, az  $Y$ -é 180.

Ekkor az eladott példányok számának szórása:

## Korrelációs együttható: példa

$X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100, az  $Y$ -é 180.  
Ekkor az eladott példányok számának szórása:

$$D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{100 + 180} = 16,73.$$

A bevétel szórása:

## Korrelációs együttható: példa

$X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100, az  $Y$ -é 180.  
Ekkor az eladott példányok számának szórása:

$$D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{100 + 180} = 16,73.$$

A bevétel szórása:

$$\begin{aligned} D(300X + 400Y) &= \sqrt{300^2 D^2(X) + 400^2 D^2(Y)} = \\ &= \sqrt{300^2 \cdot 100 + 400^2 \cdot 180} = 6148,17. \end{aligned}$$

Ezek alapján a korrelációs együttható:

## Korrelációs együttható: példa

$X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100, az  $Y$ -é 180. Ekkor az eladott példányok számának szórása:

$$D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{100 + 180} = 16,73.$$

A bevétel szórása:


$$\begin{aligned} D(300X + 400Y) &= \sqrt{300^2 D^2(X) + 400^2 D^2(Y)} = \\ &= \sqrt{300^2 \cdot 100 + 400^2 \cdot 180} = 6148,17. \end{aligned}$$

Ezek alapján a korrelációs együttható:

$$\begin{aligned} R(X + Y, 300X + 400Y) &= \frac{\text{cov}(X + Y, 300X + 400Y)}{D(X + Y)D(300X + 400Y)} = \\ &= \frac{102000}{16,73 \cdot 6148,17} = 0,9915. \end{aligned}$$

A korrelációs együttható lehetséges legnagyobb értéke **1**, így ez **erős pozitív korrelációt** jelent.

## Korrelációs együttható: példa



A bevétel ( $300X + 400Y$ ) és az eladott példányszám ( $X + Y$ ) együttes előfordulása  $n = 100$  független megfigyelésből. Kovariancia: **102000**, korrelációs együttható: **0,9915**.

## Korrelációs együttható: példa.

**Példa.** Egy üzletben az  $A$  és  $B$  újság forgalmát figyelik. Legyen az  $A$  újságból egy nap alatt eladott példányok száma  $X$ , a  $B$  újságból eladott példányok száma  $Y$ . Tegyük fel, hogy  $X$  és  $Y$  függetlenek, Poisson-eloszlásúak,  $X$  paramétere 100,  $Y$ -é 180. Az  $A$  újság ára 300 forint, a  $B$ -é **4000**. Mennyi az összesen eladott példányok számának és az ezekből származó bevételnek a korrelációs együtthatója?

$$\text{cov}(X + Y, 300X + 4000Y) = 300 \cdot 100 + 4000 \cdot 180 = 750000;$$


$$D(X + Y) = \sqrt{D^2(X) + D^2(Y)} = \sqrt{100 + 180} = 16,73;$$

$$\begin{aligned} D(300X + 4000Y) &= \sqrt{300^2 D^2(X) + 4000^2 D^2(Y)} = \\ &= \sqrt{300^2 \cdot 100 + 4000^2 \cdot 180} = 53749,42; \end{aligned}$$

$$\begin{aligned} R(X + Y, 300X + 4000Y) &= \frac{\text{cov}(X + Y, 300X + 4000Y)}{D(X + Y)D(300X + 4000Y)} = \\ &= \frac{750000}{16,73 \cdot 53749,42} = 0,83. \end{aligned}$$

A korrelációs együttható értéke kisebb, mint hasonló ár esetén.

## Korrelációs együttható: példa



A bevétel ( $300X + 4000Y$ ) és az eladott példányszám ( $X + Y$ ) együttes előfordulása  $n = 100$  megfigyelésből. Kovariancia: 750000, korrelációs együttható: 0,83.

# Korreláció és ok-okozat

- napsütéses órák száma és hőmérséklet:

# Korreláció és ok-okozat

- napsütéses órák száma és hőmérséklet: pozitív korreláció, **van ok-okozati összefüggés**
- napsütéses órák száma és hómennyiség:

## Korreláció és ok-okozat

- napsütéses órák száma és hőmérséklet: pozitív korreláció, **van ok-okozati összefüggés**
- napsütéses órák száma és hómennyiség: negatív korreláció, van ok-okozati összefüggés
- anyagi helyzet és iskolai végzettség:

## Korreláció és ok-okozat

- napsütéses órák száma és hőmérséklet: pozitív korreláció, **van ok-okozati összefüggés**
- napsütéses órák száma és hómennyiség: negatív korreláció, van ok-okozati összefüggés
- anyagi helyzet és iskolai végzettség: van pozitív korreláció, de mindkét irányban lehet ok-okozati összefüggés
- tengerparton töltött idő és egészség:


## Korreláció és ok-okozat

- napsütéses órák száma és hőmérséklet: pozitív korreláció, **van ok-okozati összefüggés**
- napsütéses órák száma és hómennyiség: negatív korreláció, van ok-okozati összefüggés
- anyagi helyzet és iskolai végzettség: van pozitív korreláció, de mindkét irányban lehet ok-okozati összefüggés
- tengerparton töltött idő és egészség:  
ha van is pozitív korreláció, **nem biztos, hogy van ok-okozati összefüggés**, a tengerparton töltött idő összefügg az anyagi helyzettel, ami az egészséggel, de csak a tengerparttól nem biztos, hogy egészséges lesz valaki, illetve aki beteg, kevésbé megy a tengerpartra
- a válások aránya Maine államban és a fejenkénti margarin fogyasztás az USA-ban:

## Korreláció és ok-okozat

- napsütéses órák száma és hőmérséklet: pozitív korreláció, **van ok-okozati összefüggés**
- napsütéses órák száma és hómennyiség: negatív korreláció, van ok-okozati összefüggés
- anyagi helyzet és iskolai végzettség: van pozitív korreláció, de mindkét irányban lehet ok-okozati összefüggés
- tengerparton töltött idő és egészség:  
ha van is pozitív korreláció, **nem biztos, hogy van ok-okozati összefüggés**, a tengerparton töltött idő összefügg az anyagi helyzettel, ami az egészséggel, de csak a tengerparttól nem biztos, hogy egészséges lesz valaki, illetve aki beteg, kevésbé megy a tengerpartra
- a válások aránya Maine államban és a fejenkénti margarinfogyasztás az USA-ban: van pozitív korreláció ( $R = 0,9926$ ), de **feltehetően nincs ok-okozati összefüggés** (forrás és további példák: <http://tylervigen.com/spurious-correlations>)


# Korreláció és ok-okozat



A válások aránya Maine államban és a fejenkénti margarin fogyasztás az USA-ban, korrelációs együttható: 0,9926

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

# Korreláció és ok-okozat



A válások aránya Maine államban és a fejenkénti margarin fogyasztás az USA-ban, korrelációs együttható: 0,9926

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

„Big data” analízis: 200-300 mennyiség között könnyen található néhány olyan pár, amik ok-okozati összefüggés nélkül is nagy pozitív korrelációval rendelkeznek, de olyanok is, amik között valós összefüggés van → mindez alaposabb vizsgálatot igényel.