

## Korreláció-, és regresszióanalízis

Két mérhető (kvantitatív) mennyiség közötti kapcsolat

(ha egyáltalán létezik) lehet

→ **determinisztikus** ( pl.  $T=a \cdot b$


→ **sztochasztikus**, azaz a véletlen is befolyásolja, X minden értékéhez Y különböző kimenetelei tartoznak (pl. geodéziai mérések ismétlései)

Az ilyen sztochasztikus kapcsolatok elemzésére szolgál a korrelációanalízis és a regresszióanalízis.


**Korreláció** - a lineáris, vagy arra visszavezethető kapcsolatokat **szorosságát** méri.

**Regresszió** - az X és Y valószínűségi változók közötti kapcsolatot „legjobban” leíró függvényt keresi meg.


Ha kellő számú összetartozó mérést végeztünk X és Y-ra, akkor először célszerű egy megfelelő léptékű koordináta-rendszerben ábrázolni őket és alaposan megnézni.



Elkent pontfelhő a kép  $\Rightarrow$  valószínűleg X és Y **függetlenek**



Határozott tendencia mutatkozik X és Y között (itt jól sejthetően **lineáris**)



Határozott tendencia mutatkozik X és Y között (itt jól sejthetően **nem lineáris**)

## I. Lineáris korreláció számítás

$$\rho = \frac{E(XY) - E(X)E(Y)}{D(X)D(Y)} \quad \text{az elméleti korrelációs együttható}$$

ez méri az X és Y változók közötti lin. kapcsolatot szorosságát

$$r = \frac{\sum_{i=1}^n x_i \cdot y_i - \frac{1}{n} \sum_{i=1}^n x_i \cdot \sum_{i=1}^n y_i}{\sqrt{\left[ \sum_{i=1}^n x_i^2 - \frac{1}{n} \left( \sum_{i=1}^n x_i \right)^2 \right] \cdot \left[ \sum_{i=1}^n y_i^2 - \frac{1}{n} \left( \sum_{i=1}^n y_i \right)^2 \right]}} = \frac{SP_{xy}}{\sqrt{SQ_x \cdot SQ_y}}$$

**r a tapasztalati korrelációs együttható**, ezzel becsüljük a  $\rho$  értékét a konkrét  $x_i$  és  $y_i$  mérési párok segítségével.

Tulajdonságai:

1. **r** értéke mindig -1 és +1 közötti,
2. teljes függetlenség esetén 0, ha pedig minden pont azonos egyenesen van +1 vagy -1,
3. minél szorosabb a kapcsolat **r** absz. értéke annál közelebb van 1-hez,
4. előjele + akkor növekvő, ha - akkor csökkenő a kapcsolat tendenciája.

### A lineáris korrelációs együttható próbája

Ha **r** nem 0, akkor is lehet nagy valószínűséggel inkább független a kapcsolat és az a határ, hogy miként döntünk **n**-től és  $\varepsilon$ -tól is nagyban függ.

**H<sub>0</sub>:  $\rho=0$**  (azaz X és Y lineárisan függetlenek)

**H<sub>1</sub>:  $\rho \neq 0$**  (azaz X és Y lineárisan összefüggnek és van értelme a legjobban illeszkedő lin. fv-t megkeresni)

#### Próba statisztika:

A X. táblázatból **n** és  $\varepsilon$  ismeretében kikeressük a kritikus értéket és **K:  $\{ |r| > r_{\varepsilon} \}$**  Szab. fok: **n-2** ! alapján döntünk.


**Ha  $r \in K$ , akkor H<sub>0</sub> -t elvetjük és megkeressük a legjobban illeszkedő függvényt, ha  $r \notin K$ , akkor nincs igazolható kapcsolat.**

## II. Lineáris regresszió elve és kiszámítása

Keressük az  $Y=a+b \cdot X$  lineáris függvényt úgy, hogy a **mérési pontok és az illesztett egyenes függőleges távolságainak négyzetösszege a lehető legkisebb legyen.**

Ezt hívjuk: **legkisebb négyzetek módszerének** (Least Squared Method)

**Azaz:**



$$\sum_{i=1}^n (y_i - y)^2 \rightarrow \text{minimumát keressük!}$$

$$\sum_{i=1}^n (y_i - a - bx_i)^2 \text{ - nek milyen } a \text{ és } b$$

esetén van szélsőértéke?

$$f : (a; b) \mapsto \sum_{i=1}^n (y_i - a - bx_i)^2 \text{ kétváltozós függvénynek } k$$

akkor lehet szélsőértéke, ha  $f'_a = 0$  és  $f'_b = 0$ .

Ez akkor következik be, ha

$$b = \frac{\sum_{i=1}^n x_i \cdot y_i - \frac{1}{n} \sum_{i=1}^n x_i \cdot \sum_{i=1}^n y_i}{\left[ \sum_{i=1}^n x_i^2 - \frac{1}{n} \left( \sum_{i=1}^n x_i \right)^2 \right]} = \frac{SP_{xy}}{SQ_x}$$

$$a = \frac{\sum_{i=1}^n y_i}{n} - b \frac{\sum_{i=1}^n x_i}{n} = \bar{y} - b \cdot \bar{x}$$


$y=a+b \cdot x$  az egyenes egyenlete,

$$r = \frac{SP_{xy}}{\sqrt{SQ_x \cdot SQ_y}}$$

pedig méri az illeszkedés szorosságát.

# Lineárisra visszavezethető nemlineáris regressziós függvények

## 1. Hiperbolikus függvények



$$y = \frac{1}{a + bx}$$

**Linearizálás:**


$$\frac{1}{y} = a + bx$$

$$y^* = a + bx$$


$$y = a + b \left( \frac{1}{x} \right)$$

**Linearizálás:**

$$y = a + b \cdot x^*$$



## 2. Hatvány függvények



**Linearizálása:**

$$y = c \cdot x^b$$

$$\ln y = \ln c + b \ln x$$

$$y^* = a + b \cdot x^*$$

tehát az eredeti adatok helyett az ln -jeik és  $c = e^a$  -ból adódik az együttható


## 3. Exponenciális függvény

**Linearizálva:**

$$y = c \cdot e^{bx}$$

$$\ln y = \ln c + bx \cdot \ln e$$


$$y^* = a + b \cdot x$$



#### 4. Logaritmus függvény

$y = a + b \cdot \log x$ , ahol log tetszőleges alapú lehet.

**Linearizálva:**  $y = a + b \cdot x^*$   
 $x^* = \log x$  a transzformáció.



#### 5. Telítődési függvény


$y = A(1 - ce^{bx})$ ,  $b < 0$   
 és A-t az adatokból becsülni kell.

$$A - y = ce^{bx}$$

$$ce^{bx} = \frac{A - y}{A}$$

$$\ln c + \ln e^{bx} = \ln \frac{A - y}{A}$$

$$\ln c + bx = y^*$$



#### 6. Logisztikus fv. (szigmoid görbe)

$$y = \frac{A}{1 + ce^{-bx}}$$

ahol  $b < 0$  és A becsülendő az adatokból.

$$\frac{A - y}{y} = ce^{-bx}$$

$$\ln \frac{A - y}{y} = \ln c - bx$$

$$y^* = a + bx$$

