

# Statisztika

Nagy Gergely Gábor

BME SZIT

2012. május 3.

# Vázlat

- Valószínűségszámítási alapok
- Becsléelmélet
- Hipotéziselmélet

## Valószínűségi mező definíciója

$(\Omega, \mathcal{F}, P)$  hármas **valószínűségi mező**, ha

- $\Omega$ : alaphalmaz (elemi események)

## Valószínűségi mező definíciója

$(\Omega, \mathcal{F}, P)$  hármas **valószínűségi mező**, ha

- $\Omega$ : alaphalmaz (elemi események)
- $\mathcal{F} \subseteq 2^\Omega$   $\sigma$ -algebra (események, mérhető halmazok)
  - $\mathcal{F} \neq \emptyset$
  - $A \in \mathcal{F} \implies \Omega \setminus A \in \mathcal{F}$
  - $A_1, A_2, \dots \in \mathcal{F} \implies A_1 \cup A_2 \cup \dots \in \mathcal{F}$

## Valószínűségi mező definíciója

$(\Omega, \mathcal{F}, P)$  hármas **valószínűségi mező**, ha

- $\Omega$ : alaphalmaz (elemi események)
- $\mathcal{F} \subseteq 2^\Omega$   $\sigma$ -algebra (események, mérhető halmazok)
  - $\mathcal{F} \neq \emptyset$
  - $A \in \mathcal{F} \implies \Omega \setminus A \in \mathcal{F}$
  - $A_1, A_2, \dots \in \mathcal{F} \implies A_1 \cup A_2 \cup \dots \in \mathcal{F}$
- $P : \mathcal{F} \rightarrow [0,1]$   $\sigma$ -additív (valószínűségfv)
  - $A_1, A_2, \dots \in \mathcal{F}$  diszjunktak  
 $\implies P(A_1 \cup A_2 \cup \dots) = P(A_1) + P(A_2) + \dots$
  - $P(\Omega) = 1$

## Diszkrét példa

$$\Omega = \{\text{fej, írás}\}$$

## Diszkrét példa

$$\Omega = \{\text{fej}, \text{írás}\}$$

$$\mathcal{F} = 2^\Omega = \{\emptyset, \{\text{fej}\}, \{\text{írás}\}, \{\text{fej}, \text{írás}\}\}$$

## Diszkrét példa

$$\Omega = \{\text{fej}, \text{írás}\}$$

$$\mathcal{F} = 2^\Omega = \{\emptyset, \{\text{fej}\}, \{\text{írás}\}, \{\text{fej}, \text{írás}\}\}$$

$$P(\emptyset) = 0$$

$$P(\{\text{fej}\}) = \frac{1}{2}$$

$$P(\{\text{írás}\}) = \frac{1}{2}$$

$$P(\{\text{fej}, \text{írás}\}) = 1$$



## Valószínűségi változó definíciója (valós eset)

$X : \Omega \rightarrow \mathbb{R}$  valószínűségi változó, ha

- mérhető, azaz  $\forall x \in \mathbb{R}$ -re

$$X^{-1}((-\infty, x]) = \{\omega \in \Omega \mid X(\omega) \leq x\} \in \mathcal{F}$$

## Valószínűségi változó definíciója (valós eset)

$X : \Omega \rightarrow \mathbb{R}$  valószínűségi változó, ha

- mérhető, azaz  $\forall x \in \mathbb{R}$ -re

$$X^{-1}((-\infty, x]) = \{\omega \in \Omega \mid X(\omega) \leq x\} \in \mathcal{F}$$

X eloszlása  $Q = P \circ X^{-1}$

## Valószínűségi változó definíciója (valós eset)

$X : \Omega \rightarrow \mathbb{R}$  **valószínűségi változó**, ha

- mérhető, azaz  $\forall x \in \mathbb{R}$ -re

$$X^{-1}((-\infty, x]) = \{\omega \in \Omega \mid X(\omega) \leq x\} \in \mathcal{F}$$

X **eloszlása**  $Q = P \circ X^{-1}$

X **eloszlásfüggvénye**  $F : \mathbb{R} \rightarrow [0,1]$ , ha

- $\forall x \in \mathbb{R}$ -re  $F(x) = Q((-\infty, x]) = P(X \leq x)$

## Valószínűségi változó definíciója (valós eset)

$X : \Omega \rightarrow \mathbb{R}$  **valószínűségi változó**, ha

- mérhető, azaz  $\forall x \in \mathbb{R}$ -re

$$X^{-1}((-\infty, x]) = \{\omega \in \Omega \mid X(\omega) \leq x\} \in \mathcal{F}$$

X **eloszlása**  $Q = P \circ X^{-1}$

X **eloszlásfüggvénye**  $F : \mathbb{R} \rightarrow [0,1]$ , ha

- $\forall x \in \mathbb{R}$ -re  $F(x) = Q((-\infty, x]) = P(X \leq x)$

X **sűrűségfüggvénye**  $f : \mathbb{R} \rightarrow [0, \infty)$ , ha

- $\forall x \in \mathbb{R}$ -re  $F(x) = \int_{-\infty}^x f(u)du$
- (Ha  $F$  deriválható, akkor  $f = F'$ )

# Várható érték, szórásnégyzet

X **várható értéke**  $E(X) = \int_{-\infty}^{\infty} xf(x)dx$

## Várható érték, szórásnégyzet

$X$  várható értéke  $E(X) = \int_{-\infty}^{\infty} xf(x)dx$

$h(X)$  várható értéke  $E(h(X)) = \int_{-\infty}^{\infty} h(x)f(x)dx$

## Várható érték, szórásnégyzet

X **várható értéke**  $E(X) = \int_{-\infty}^{\infty} xf(x)dx$

$h(X)$  várható értéke  $E(h(X)) = \int_{-\infty}^{\infty} h(x)f(x)dx$

X **szórásnégyzete**  $D^2(X) = E((X - E(X))^2) = E(X^2) - E^2(X)$

# Normális eloszlás

$N(\mu, \sigma^2)$  normális eloszlás

- sűrűségfüggvénye  $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
- eloszlásfüggvénye  $F(x) = \frac{1}{2} \left( 1 + \operatorname{erf} \left( \frac{x-\mu}{\sqrt{2\pi\sigma^2}} \right) \right)$
- várható értéke  $\mu$
- szórásnégyzete  $\sigma^2$



# Normális eloszlás



## $N(\mu, \sigma^2)$ normális eloszlás

- sűrűségfüggvénye  $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
- eloszlásfüggvénye  $F(x) = \frac{1}{2} \left( 1 + \operatorname{erf} \left( \frac{x-\mu}{\sqrt{2\pi\sigma^2}} \right) \right)$
- várható értéke  $\mu$
- szórásnégyzete  $\sigma^2$

## $N(0,1)$ standard normális eloszlás

- sűrűségfüggvénye  $f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$
- eloszlásfüggvénye  $F(x) = \Phi(x) = \frac{1}{2} \left( 1 + \operatorname{erf} \left( \frac{x}{\sqrt{2\pi}} \right) \right)$
- várható értéke 0
- szórásnégyzete 1

# Normális eloszlás



# Centrális határeloszlás-tétel

Miért jó a normális eloszlás?

## Centrális határeloszlás-tétel

Miért jó a normális eloszlás?

Legyenek  $X_1, X_2, \dots$  azonos eloszlású független valószínűségi változók  $\mu$  várható értékkel és  $\sigma^2$  véges szórásnégyzettel.

Legyen  $S_n = \frac{X_1 + X_2 + \dots + X_n}{n}$  az első  $n$  változó átlaga.

## Centrális határeloszlás-tétel

Miért jó a normális eloszlás?

Legyenek  $X_1, X_2, \dots$  azonos eloszlású független valószínűségi változók  $\mu$  várható értékkel és  $\sigma^2$  véges szórásnégyzettel.

Legyen  $S_n = \frac{X_1 + X_2 + \dots + X_n}{n}$  az első  $n$  változó átlaga.

Centrális határeloszlás-tétel:  $\sqrt{n}(S_n - \mu) \xrightarrow{d} N(0, \sigma^2)$

Átrendezgetve:  $S_n \approx N\left(\mu, \frac{\sigma^2}{n}\right)$

## Statisztikai mező definíciója

$(\Omega, \mathcal{F}, \mathcal{P})$  hármas **statisztikai mező**, ha

- $\forall P \in \mathcal{P}$ -re  $(\Omega, \mathcal{F}, P)$  valószínűségi mező

## Statisztikai mező definíciója

$(\Omega, \mathcal{F}, \mathcal{P})$  hármas **statisztikai mező**, ha

- $\forall P \in \mathcal{P}$ -re  $(\Omega, \mathcal{F}, P)$  valószínűségi mező

Paraméteres alak:  $\mathcal{P} = \{P_\vartheta \mid \vartheta \in \Theta\}$ , gyakran  $\Theta \subseteq \mathbb{R}^p$

## Statisztikai mező definíciója

$(\Omega, \mathcal{F}, \mathcal{P})$  hármas **statisztikai mező**, ha

- $\forall P \in \mathcal{P}$ -re  $(\Omega, \mathcal{F}, P)$  valószínűségi mező

Paraméteres alak:  $\mathcal{P} = \{P_\vartheta \mid \vartheta \in \Theta\}$ , gyakran  $\Theta \subseteq \mathbb{R}^p$

Mi most feltesszük, hogy minden  $P_\vartheta$ -nak van  $f_\vartheta$  sűrűségfüggvénye.



# Minta

**Minta:**  $X : \Omega \rightarrow \mathcal{X}$  mérhető leképezés ( $\mathcal{X}$  a mintatér)

# Minta

**Minta:**  $X : \Omega \rightarrow \mathcal{X}$  mérhető leképezés ( $\mathcal{X}$  a mintatér)

Spec. eset ( $n$  elemű független minta):

- $X = (X_1, \dots, X_n)$ , ahol  $X_1, \dots, X_n$  azonos eloszlású, független változók.

# Statisztika

**Statisztika:**  $T : \mathcal{X} \rightarrow \dots$  mérhető függvény

# Statisztika

**Statisztika:**  $T : \mathcal{X} \rightarrow \dots$  mérhető függvény

Például:

- **Átlag:**  $T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

# Statisztika

**Statisztika:**  $T : \mathcal{X} \rightarrow \dots$  mérhető függvény

Például:

- **Átlag:**  $T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$
- **Tapasztalati szórásnégyzet:**  $T(X) = s_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$

# Statisztika

**Statisztika:**  $T : \mathcal{X} \rightarrow \dots$  mérhető függvény

Például:

- **Átlag:**  $T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$
- **Tapasztalati szórásnégyzet:**  $T(X) = s_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$
- **Korrigált tapasztalati szórásnégyzet:**  
 $T(X) = s_n^{*2} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$

# Statisztika

**Statisztika:**  $T : \mathcal{X} \rightarrow \dots$  mérhető függvény

Például:

- **Átlag:**  $T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$
- **Tapasztalati szórásnégyzet:**  $T(X) = s_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$
- **Korrigált tapasztalati szórásnégyzet:**  
 $T(X) = s_n^{*2} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
- **Tapasztalati eloszlás:**  $T(X) = Q_n^*$ , ahol  
 $Q_n^*(B) = \frac{1}{n} \sum_{i=1}^n I(X_i \in B)$

# Statisztika

**Statisztika:**  $T : \mathcal{X} \rightarrow \dots$  mérhető függvény

Például:

- **Átlag:**  $T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$
- **Tapasztalati szórásnégyzet:**  $T(X) = s_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$
- **Korrigált tapasztalati szórásnégyzet:**  
 $T(X) = s_n^{*2} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
- **Tapasztalati eloszlás:**  $T(X) = Q_n^*$ , ahol  
 $Q_n^*(B) = \frac{1}{n} \sum_{i=1}^n I(X_i \in B)$
- **Tapasztalati eloszlásfüggvény:**  $T(X) = F_n^*$ , ahol  
 $F_n^*(x) = \frac{1}{n} \sum_{i=1}^n I(X_i \leq x)$



## Glivenko-Cantelli tétel (a statisztika alaptétele)

Glivenko-Cantelli tétel:  $P(\sup_{x \in \mathbb{R}} |F_n^*(x) - F(x)| \rightarrow 0) = 1$ ,  
azaz a tapasztalati eloszlásfüggvény 1 valószínűséggel egyenletesen  
konvergál a valódihoz.

# Beclés

$\varphi(P)$ -t szeretnénk becsülni, ahol  $\varphi : \mathcal{P} \rightarrow \mathbb{R}^k$  függvény.

Ha  $\mathcal{P} = \{P_\vartheta \mid \vartheta \in \Theta\}$ , akkor  $g(\vartheta) = \varphi(P_\vartheta)$ -t kell becsülnünk.

# Beccslés

$\varphi(P)$ -t szeretnénk beccsülni, ahol  $\varphi : \mathcal{P} \rightarrow \mathbb{R}^k$  függvény.

Ha  $\mathcal{P} = \{P_\vartheta \mid \vartheta \in \Theta\}$ , akkor  $g(\vartheta) = \varphi(P_\vartheta)$ -t kell beccsülnünk.

$g(\vartheta)$  **beccslése**:  $T : \mathcal{X} \rightarrow \mathbb{R}^k$

# Becslés

$\varphi(P)$ -t szeretnénk becsülni, ahol  $\varphi : \mathcal{P} \rightarrow \mathbb{R}^k$  függvény.

Ha  $\mathcal{P} = \{P_\vartheta \mid \vartheta \in \Theta\}$ , akkor  $g(\vartheta) = \varphi(P_\vartheta)$ -t kell becsülnünk.

$g(\vartheta)$  **becslése**:  $T : \mathcal{X} \rightarrow \mathbb{R}^k$

$T$  **torzítatlan becslés**, ha

- $\forall \vartheta \in \Theta$ -ra  $E_{\vartheta}(T(X)) = g(\vartheta)$

# Beclés

$\varphi(P)$ -t szeretnénk becsülni, ahol  $\varphi : \mathcal{P} \rightarrow \mathbb{R}^k$  függvény.

Ha  $\mathcal{P} = \{P_\vartheta \mid \vartheta \in \Theta\}$ , akkor  $g(\vartheta) = \varphi(P_\vartheta)$ -t kell becsülnünk.

$g(\vartheta)$  **becslése**:  $T : \mathcal{X} \rightarrow \mathbb{R}^k$

$T$  **torzítatlan beclés**, ha

$$\blacksquare \forall \vartheta \in \Theta\text{-ra } E_{\vartheta}(T(X)) = g(\vartheta)$$

$T$  **torzítása**  $b_T(\vartheta) = E_{\vartheta}(T(X)) - g(\vartheta)$

## Veszteség, rizikó

$w : \mathbb{R}^k \times \Theta \rightarrow \mathbb{R}$  **veszteségfüggvény**, ahol

- (jelentése: ha  $\vartheta$  az igazi paraméter és  $g(\vartheta)$ -t  $T$ -vel becsüljük, akkor a veszteségünk  $w(T, \vartheta)$  )
- $w(g(\vartheta), \vartheta) = 0$
- $w(T, \vartheta) \geq 0$
- $w$  első változójában konvex

## Veszteség, rizikó

$w : \mathbb{R}^k \times \Theta \rightarrow \mathbb{R}$  **veszteségfüggvény**, ahol

- (jelentése: ha  $\vartheta$  az igazi paraméter és  $g(\vartheta)$ -t  $T$ -vel becsüljük, akkor a veszteségünk  $w(T, \vartheta)$  )
- $w(g(\vartheta), \vartheta) = 0$
- $w(T, \vartheta) \geq 0$
- $w$  első változójában konvex

$T$  **rizikófüggvénye**  $R_T(\vartheta) = E_{\vartheta}(w(T(X), \vartheta))$  (az átlagos veszteség)

## Veszteség, rizikó

$w : \mathbb{R}^k \times \Theta \rightarrow \mathbb{R}$  **veszteségfüggvény**, ahol

- (jelentése: ha  $\vartheta$  az igazi paraméter és  $g(\vartheta)$ -t  $T$ -vel becsüljük, akkor a veszteségünk  $w(T, \vartheta)$  )
- $w(g(\vartheta), \vartheta) = 0$
- $w(T, \vartheta) \geq 0$
- $w$  első változójában konvex

$T$  **rizikófüggvénye**  $R_T(\vartheta) = E_{\vartheta}(w(T(X), \vartheta))$  (az átlagos veszteség)

Példa (négyzetes veszteségfüggvény):

- $w(T, \vartheta) = \|T - g(\vartheta)\|^2$



## Veszteség, rizikó

$w : \mathbb{R}^k \times \Theta \rightarrow \mathbb{R}$  **veszteségfüggvény**, ahol

- (jelentése: ha  $\vartheta$  az igazi paraméter és  $g(\vartheta)$ -t  $T$ -vel becsüljük, akkor a veszteségünk  $w(T, \vartheta)$  )
- $w(g(\vartheta), \vartheta) = 0$
- $w(T, \vartheta) \geq 0$
- $w$  első változójában konvex

$T$  **rizikófüggvénye**  $R_T(\vartheta) = E_{\vartheta}(w(T(X), \vartheta))$  (az átlagos veszteség)

Példa (négyzetes veszteségfüggvény):

- $w(T, \vartheta) = \|T - g(\vartheta)\|^2$
- $R_T(\vartheta) = E_{\vartheta}(\|T - g(\vartheta)\|^2)$

## Veszteség, rizikó

$w : \mathbb{R}^k \times \Theta \rightarrow \mathbb{R}$  **veszteségfüggvény**, ahol

- (jelentése: ha  $\vartheta$  az igazi paraméter és  $g(\vartheta)$ -t  $T$ -vel becsüljük, akkor a veszteségünk  $w(T, \vartheta)$  )
- $w(g(\vartheta), \vartheta) = 0$
- $w(T, \vartheta) \geq 0$
- $w$  első változójában konvex

$T$  **rizikófüggvénye**  $R_T(\vartheta) = E_{\vartheta}(w(T(X), \vartheta))$  (az átlagos veszteség)

Példa (négyzetes veszteségfüggvény):

- $w(T, \vartheta) = \|T - g(\vartheta)\|^2$
- $R_T(\vartheta) = E_{\vartheta}(\|T - g(\vartheta)\|^2)$
- $k = 1$  esetben  $R_T(\vartheta) = E_{\vartheta}((T - g(\vartheta))^2) = D_{\vartheta}^2(T - g(\vartheta)) + E_{\vartheta}^2(T - g(\vartheta)) = D_{\vartheta}^2(T) + b_T^2(\vartheta)$

## Beclések összehasonlítása

$T_1, T_2$  beclések ugyanarra a  $g(\vartheta)$ -ra. Melyik a jobb?

## Beclések összehasonlítása

$T_1, T_2$  beclések ugyanarra a  $g(\vartheta)$ -ra. Melyik a jobb?

$T_1$  **jobb** („nem rosszabb”), mint  $T_2$ , ha  $\vartheta R_{T_1}(\vartheta) \leq R_{T_2}(\vartheta)$  fennáll minden  $\vartheta$ -ra.

## Beclések összehasonlítása

$T_1, T_2$  beclések ugyanarra a  $g(\vartheta)$ -ra. Melyik a jobb?

$T_1$  **jobb** („nem rosszabb”), mint  $T_2$ , ha  $\vartheta R_{T_1}(\vartheta) \leq R_{T_2}(\vartheta)$  fennáll minden  $\vartheta$ -ra.

Legyen  $\mathcal{D}$  beclések egy osztálya.  $T \in \mathcal{D}$  **optimális**, ha minden  $\mathcal{D}$ -beli beclésnél jobb.

## Beclések összehasonlítása

$T_1, T_2$  beclések ugyanarra a  $g(\vartheta)$ -ra. Melyik a jobb?

$T_1$  **jobb** („nem rosszabb”), mint  $T_2$ , ha  $\vartheta R_{T_1}(\vartheta) \leq R_{T_2}(\vartheta)$  fennáll minden  $\vartheta$ -ra.

Legyen  $\mathcal{D}$  beclések egy osztálya.  $T \in \mathcal{D}$  **optimális**, ha minden  $\mathcal{D}$ -beli beclésnél jobb.

Ha  $\mathcal{D}$  a torzítatlan beclések osztálya, és  $w$  négyzetes veszteségfüggvény, akkor az optimálist **hatásosnak** hívjuk. Gyakran **MVUE** (minimum-variance unbiased estimator).

# Tapasztalati becslés

Ha  $\varphi$  az eloszlásokon van értelmezve,  $\varphi(Q)$ -t szeretnénk becsülni,  $Q$  a valódi eloszlásfüggvény.

**Tapasztalati becslés:**  $\varphi(Q)$ -t  $\varphi(Q_n^*)$ -gal becsüljük.

## Tapasztalati becslés

Ha  $\varphi$  az eloszlásokon van értelmezve,  $\varphi(Q)$ -t szeretnénk becsülni,  $Q$  a valódi eloszlásfüggvény.

**Tapasztalati becslés:**  $\varphi(Q)$ -t  $\varphi(Q_n^*)$ -gal becsüljük.

Például:

- Az átlag ( $\bar{X}$ ) a várható érték ( $E$ ) tapasztalati becslése.



## Tapasztalati beclés

Ha  $\varphi$  az eloslásokon van értelmezve,  $\varphi(Q)$ -t szeretnénk becsülni,  $Q$  a valódi eloslásfüggvény.

**Tapasztalati beclés:**  $\varphi(Q)$ -t  $\varphi(Q_n^*)$ -gal becsüljük.

Például:

- Az átlag ( $\bar{X}$ ) a várható érték ( $E$ ) tapasztalati beclése.
- A tapasztalati szórásnégyzet ( $s_n^2$ ) a szórásnégyzet ( $D^2$ ) tapasztalati beclése.

## Tapasztalati becslés

Ha  $\varphi$  az eloszlásokon van értelmezve,  $\varphi(Q)$ -t szeretnénk becsülni,  $Q$  a valódi eloszlásfüggvény.

**Tapasztalati becslés:**  $\varphi(Q)$ -t  $\varphi(Q_n^*)$ -gal becsüljük.

Például:

- Az átlag ( $\bar{X}$ ) a várható érték ( $E$ ) tapasztalati becslése.
- A tapasztalati szórásnégyzet ( $s_n^2$ ) a szórásnégyzet ( $D^2$ ) tapasztalati becslése.
- A tapasztalati eloszlásfüggvény ( $F_n^*$ ) az eloszlásfüggvény ( $F$ ) tapasztalati becslése.

# Momentum-módszer

Legyen most  $g(\vartheta) = \vartheta$ , azaz magát a paramétert szeretnénk becsülni ( $\vartheta \in \Theta \subseteq \mathbb{R}^p$ )

## Momentum-módszer

Legyen most  $g(\vartheta) = \vartheta$ , azaz magát a paramétert szeretnénk becsülni ( $\vartheta \in \Theta \subseteq \mathbb{R}^p$ )

Válasszunk egy olyan  $f : \mathcal{X} \rightarrow \mathbb{R}^p$  függvényt, amire  $h(\vartheta) = E_{\vartheta}(f(X_1))$  invertálható  $\mathbb{R}^p \rightarrow \mathbb{R}^p$  leképezés.

## Momentum-módszer

Legyen most  $g(\vartheta) = \vartheta$ , azaz magát a paramétert szeretnénk becsülni ( $\vartheta \in \Theta \subseteq \mathbb{R}^p$ )

Válasszunk egy olyan  $f : \mathcal{X} \rightarrow \mathbb{R}^p$  függvényt, amire  $h(\vartheta) = E_{\vartheta}(f(X_1))$  invertálható  $\mathbb{R}^p \rightarrow \mathbb{R}^p$  leképezés.

$h(\vartheta)$ -t  $n$  elemű mintából így becsülhetjük:  $\frac{1}{n} \sum_{i=1}^n f(X_i)$

## Momentum-módszer

Legyen most  $g(\vartheta) = \vartheta$ , azaz magát a paramétert szeretnénk becsülni ( $\vartheta \in \Theta \subseteq \mathbb{R}^p$ )

Válasszunk egy olyan  $f : \mathcal{X} \rightarrow \mathbb{R}^p$  függvényt, amire  $h(\vartheta) = E_{\vartheta}(f(X_1))$  invertálható  $\mathbb{R}^p \rightarrow \mathbb{R}^p$  leképezés.

$h(\vartheta)$ -t  $n$  elemű mintából így becsülhetjük:  $\frac{1}{n} \sum_{i=1}^n f(X_i)$

Ezalapján  $\vartheta$  beclése:  $T_n(X) = h^{-1} \left( \frac{1}{n} \sum_{i=1}^n f(X_i) \right)$

## Momentum-módszer

Legyen most  $g(\vartheta) = \vartheta$ , azaz magát a paramétert szeretnénk becsülni ( $\vartheta \in \Theta \subseteq \mathbb{R}^p$ )

Válasszunk egy olyan  $f : \mathcal{X} \rightarrow \mathbb{R}^p$  függvényt, amire  $h(\vartheta) = E_{\vartheta}(f(X_1))$  invertálható  $\mathbb{R}^p \rightarrow \mathbb{R}^p$  leképezés.

$h(\vartheta)$ -t  $n$  elemű mintából így becsülhetjük:  $\frac{1}{n} \sum_{i=1}^n f(X_i)$

Ezalapján  $\vartheta$  beclése:  $T_n(X) = h^{-1} \left( \frac{1}{n} \sum_{i=1}^n f(X_i) \right)$

Ezt a fajta beclést hívják **momentum-módszernek**. Miért?

## Momentum-módszer

Legyen most  $g(\vartheta) = \vartheta$ , azaz magát a paramétert szeretnénk becsülni ( $\vartheta \in \Theta \subseteq \mathbb{R}^p$ )

Válasszunk egy olyan  $f : \mathcal{X} \rightarrow \mathbb{R}^p$  függvényt, amire  $h(\vartheta) = E_{\vartheta}(f(X_1))$  invertálható  $\mathbb{R}^p \rightarrow \mathbb{R}^p$  leképezés.

$h(\vartheta)$ -t  $n$  elemű mintából így becsülhetjük:  $\frac{1}{n} \sum_{i=1}^n f(X_i)$

Ezalapján  $\vartheta$  becslése:  $T_n(X) = h^{-1} \left( \frac{1}{n} \sum_{i=1}^n f(X_i) \right)$

Ezt a fajta becslést hívják **momentum-módszernek**. Miért?

Gyakran  $f$  olyan, hogy a koordinátái momentumok. Például  $f(x) = (x^{k_1}, x^{k_2}, \dots, x^{k_p})$ .



# Maximum-likelihood beclés

Likelihood-függvény:  $L(\vartheta | x) = f_{\vartheta}(x)$

( $n$  elemű független mintánál  $f_{\vartheta}(x) = \prod_{i=1}^n f_{\vartheta}(x_i)$ )

## Maximum-likelihood becslés

**Likelihood-függvény:**  $L(\vartheta \mid x) = f_{\vartheta}(x)$

( $n$  elemű független mintánál  $f_{\vartheta}(x) = \prod_{i=1}^n f_{\vartheta}(x_i)$ )

$\vartheta$  **ML-becslése** az a  $\hat{\vartheta} \in \Theta$  érték, amire a likelihood-függvény maximális:  $f_{\hat{\vartheta}}(x) = \max_{\vartheta \in \Theta} f_{\vartheta}(x)$ .

## Maximum-likelihood becelele

**Likelihood-függvény:**  $L(\vartheta \mid x) = f_{\vartheta}(x)$

( $n$  elemű független mintánál  $f_{\vartheta}(x) = \prod_{i=1}^n f_{\vartheta}(x_i)$ )

$\vartheta$  **ML-becelele** az a  $\hat{\vartheta} \in \Theta$  érték, amire a likelihood-függvény maximális:  $f_{\hat{\vartheta}}(x) = \max_{\vartheta \in \Theta} f_{\vartheta}(x)$ .

Nem biztos, hogy létezik, sem az hogy egyértelmű.

## Maximum-likelihood bececlés

**Likelihood-függvény:**  $L(\vartheta | x) = f_{\vartheta}(x)$

( $n$  elemű független mintánál  $f_{\vartheta}(x) = \prod_{i=1}^n f_{\vartheta}(x_i)$ )

$\vartheta$  **ML-bececlése** az a  $\hat{\vartheta} \in \Theta$  érték, amire a likelihood-függvény maximális:  $f_{\hat{\vartheta}}(x) = \max_{\vartheta \in \Theta} f_{\vartheta}(x)$ .

Nem biztos, hogy létezik, sem az hogy egyértelmű.

$g(\vartheta)$  ML-bececlése  $g(\hat{\vartheta})$ .

# Hipotézisvizsgálat

A paraméterteret két részre bontjuk:  $\Theta = \Theta_0 \dot{\cup} \Theta_1$ .

A **(null)hipotézisünk** ( $H_0$ ) az, hogy  $\vartheta \in \Theta_0$ .

Az **ellenhipotézisünk** ( $H_1$ ) pedig, hogy  $\vartheta \in \Theta_1$ .

# Hipotézisvizsgálat

A paraméterteret két részre bontjuk:  $\Theta = \Theta_0 \dot{\cup} \Theta_1$ .

A **(null)hipotézisünk** ( $H_0$ ) az, hogy  $\vartheta \in \Theta_0$ .

Az **ellenhipotézisünk** ( $H_1$ ) pedig, hogy  $\vartheta \in \Theta_1$ .

Kérdés: lehet-e tényleg, hogy teljesül  $H_0$ ?

Ez nem szimmetrikus, az a prekonceptiónk, hogy  $H_0$  igaz, ezt elfogadhatjuk vagy elvethetjük.

# Hipotézisvizsgálat

A paraméterteret két részre bontjuk:  $\Theta = \Theta_0 \dot{\cup} \Theta_1$ .

A **(null)hipotézisünk** ( $H_0$ ) az, hogy  $\vartheta \in \Theta_0$ .

Az **ellenhipotézisünk** ( $H_1$ ) pedig, hogy  $\vartheta \in \Theta_1$ .

Kérdés: lehet-e tényleg, hogy teljesül  $H_0$ ?

Ez nem szimmetrikus, az a preconcepciónk, hogy  $H_0$  igaz, ezt elfogadhatjuk vagy elvethetjük.

Két féle hiba lehet:

- **Elsőfajú hibát** követünk el, ha elvetjük  $H_0$ -t, pedig igaz. Ezt nem akarjuk!

# Hipotézisvizsgálat

A paraméterteret két részre bontjuk:  $\Theta = \Theta_0 \dot{\cup} \Theta_1$ .

A **(null)hipotézisünk** ( $H_0$ ) az, hogy  $\vartheta \in \Theta_0$ .

Az **ellenhipotézisünk** ( $H_1$ ) pedig, hogy  $\vartheta \in \Theta_1$ .

Kérdés: lehet-e tényleg, hogy teljesül  $H_0$ ?

Ez nem szimmetrikus, az a preconcepciónk, hogy  $H_0$  igaz, ezt elfogadhatjuk vagy elvethetjük.

Két féle hiba lehet:

- **Elsőfajú hibát** követünk el, ha elvetjük  $H_0$ -t, pedig igaz. Ezt nem akarjuk!
- **Másodfajú hibát** követünk el, ha elfogadjuk  $H_0$ -t, pedig hamis. Ez nem annyira nagy gond.



## Statisztikai próba

A mintateret két részre bontjuk:  $\mathcal{X} = \mathcal{X}_0 \dot{\cup} \mathcal{X}_1$ .

$\mathcal{X}_0$  az **elfogadási** és  $\mathcal{X}_1$  az **elvetési tartomány**.

## Statisztikai próba

A mintateret két részre bontjuk:  $\mathcal{X} = \mathcal{X}_0 \dot{\cup} \mathcal{X}_1$ .

$\mathcal{X}_0$  az **elfogadási** és  $\mathcal{X}_1$  az **elvetési tartomány**.

Ha  $X \in \mathcal{X}_0$ , akkor elfogadjuk  $H_0$ -t, ha pedig  $X \in \mathcal{X}_1$ , akkor elvetjük.

## Statisztikai próba

A mintateret két részre bontjuk:  $\mathcal{X} = \mathcal{X}_0 \dot{\cup} \mathcal{X}_1$ .

$\mathcal{X}_0$  az **elfogadási** és  $\mathcal{X}_1$  az **elvetési tartomány**.

Ha  $X \in \mathcal{X}_0$ , akkor elfogadjuk  $H_0$ -t, ha pedig  $X \in \mathcal{X}_1$ , akkor elvetjük.

Gyakran van egy  $T : \mathcal{X} \rightarrow \mathbb{R}$  **próbat statisztika**,  $c \in \mathbb{R}$  **kritikus érték**, és ezekkel definiáljuk  $\mathcal{X}_1$ -et:  $\mathcal{X}_1 = \{x \in \mathcal{X} \mid T(x) > c\}$

## Próba jellemzői

Legyen  $\psi(\vartheta) = P_{\vartheta}(\mathcal{X}_1)$ , azaz az elvetés valószínűsége.

- Ha  $\vartheta \in \Theta_0$ , akkor  $\psi(\vartheta)$  az elsőfajú hiba valószínűsége.
- Ha  $\vartheta \in \Theta_1$ , akkor  $\psi(\vartheta)$  annak a valószínűsége, hogy helyesen vetjük el  $H_0$ -t. Ezt a próba **erejének** hívjuk  $\vartheta$ -ban.

## Próba jellemzői

Legyen  $\psi(\vartheta) = P_{\vartheta}(\mathcal{X}_1)$ , azaz az elvetés valószínűsége.

- Ha  $\vartheta \in \Theta_0$ , akkor  $\psi(\vartheta)$  az elsőfajú hiba valószínűsége.
- Ha  $\vartheta \in \Theta_1$ , akkor  $\psi(\vartheta)$  annak a valószínűsége, hogy helyesen vetjük el  $H_0$ -t. Ezt a próba **erejének** hívjuk  $\vartheta$ -ban.


A próba **terjedelme**  $\sup_{\vartheta \in \Theta_0} \psi(\vartheta)$ , ez azt jelenti, hogy legfeljebb ekkora valószínűséggel hibázhatunk, azzal hogy  $H_0$ -t elvetjük.

Sokszor megadják, hogy mekkora terjedelmű próbát kell alkalmaznunk ( $\alpha = 0.05$  például).

## $\chi^2$ -eloszlás

Legyenek  $X_1, \dots, X_q$  független, standard normális eloszlású valószínűségi változók.

Ekkor  $Y = X_1^2 + \dots + X_q^2$  eloszlását  $q$  szabadságfokú  $\chi^2$ -eloszlásnak hívjuk ( $\chi_q^2$ )

$\chi^2$ -eloszlás

## Normális eloszlás mintái

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból. Ilyenkor

- az átlag  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$  eloszlású,



## Normális eloszlás mintái

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból. Ilyenkor

- az átlag  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$  eloszlású,
- a korrigált tapasztalati szórásnégyzet pedig  $s_n^{*2} \sim \frac{\sigma^2}{n-1} \chi_{n-1}^2$  eloszlású,

## Normális eloszlás mintái

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból. Ilyenkor

- az átlag  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$  eloszlású,
- a korigált tapasztalati szórásnégyzet pedig  $s_n^{*2} \sim \frac{\sigma^2}{n-1} \chi_{n-1}^2$  eloszlású,
- és ezek függetlenek (Fisher-Bartlett tétel)

## Egymintás u-próba (z-test)

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol  $\sigma^2$ -et ismerjük,  $\mu$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

## Egymintás u-próba (z-test)

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol  $\sigma^2$ -et ismerjük,  $\mu$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma}$$

## Egymintás u-próba (z-test)

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol  $\sigma^2$ -et ismerjük,  $\mu$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma}$$

Ez  $\mu = \mu_0$  esetben standard normális eloszlású.

## Egymintás u-próba (z-test)

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol  $\sigma^2$ -et ismerjük,  $\mu$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma}$$

Ez  $\mu = \mu_0$  esetben standard normális eloszlású.

- Egyoldali ellenhipotézis esetén legyen  
 $\mathcal{X}_1 = \{x \mid T(x) > \Phi^{-1}(1 - \alpha)\}$

## Egymintás u-próba (z-test)

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol  $\sigma^2$ -et ismerjük,  $\mu$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{\sigma}$$

Ez  $\mu = \mu_0$  esetben standard normális eloszlású.

- Egyoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{x \mid T(x) > \Phi^{-1}(1 - \alpha)\}$
- Kétoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{x \mid |T(x)| > \Phi^{-1}(1 - \frac{\alpha}{2})\}$

## Kétmintás u-próba (z-test)

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból, ahol  $\sigma_1^2, \sigma_2^2$ -t ismerjük,  $\mu_1, \mu_2$  pedig tetszőlegesen valós paraméter. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).



## Kétmintás u-próba (z-test)

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból, ahol  $\sigma_1^2, \sigma_2^2$ -t ismerjük,  $\mu_1, \mu_2$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

## Kétmintás u-próba (z-test)

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból, ahol  $\sigma_1^2, \sigma_2^2$ -t ismerjük,  $\mu_1, \mu_2$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

Ez  $\mu_1 = \mu_2$  esetben standard normális eloszlású.

## Kétmintás u-próba (z-test)

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból, ahol  $\sigma_1^2, \sigma_2^2$ -t ismerjük,  $\mu_1, \mu_2$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

Ez  $\mu_1 = \mu_2$  esetben standard normális eloszlású.

- Egyoldali ellenhipotézis esetén legyen  
 $\mathcal{X}_1 = \{(x, y) \mid T(x, y) > \Phi^{-1}(1 - \alpha)\}$

## Kétmintás u-próba (z-test)

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból, ahol  $\sigma_1^2, \sigma_2^2$ -t ismerjük,  $\mu_1, \mu_2$  pedig tetszőleges valós paraméter. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

Ez  $\mu_1 = \mu_2$  esetben standard normális eloszlású.



- Egyoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{(x, y) \mid T(x, y) > \Phi^{-1}(1 - \alpha)\}$
- Kétoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{(x, y) \mid |T(x, y)| > \Phi^{-1}(1 - \frac{\alpha}{2})\}$

## t-eloszlás

Legyen  $X \sim N(0,1)$ ,  $Y \sim \chi_q^2$  függetlenek.

Ekkor  $Z = \frac{X}{\sqrt{\frac{Y}{n}}}$  eloszlását  $q$  szabadságfokú t-eloszlásnak hívjuk ( $t_q$ )

# t-eloszlás



## Egymintás t-próba

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol most se  $\mu$ -t, se  $\sigma^2$ -et nem ismerjük. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

## Egymintás t-próba

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol most se  $\mu$ -t, se  $\sigma^2$ -et nem ismerjük. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{s_n^*}$$



## Egymintás t-próba

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol most se  $\mu$ -t, se  $\sigma^2$ -et nem ismerjük. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{s_n^*}$$

Erről a Fisher-Bartlett tétel alapján belátható, hogy  $\mu = \mu_0$  esetben  $t_{n-1}$  eloszlású.

## Egymintás t-próba

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol most se  $\mu$ -t, se  $\sigma^2$ -et nem ismerjük. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{s_n^*}$$

Erről a Fisher-Bartlett tétel alapján belátható, hogy  $\mu = \mu_0$  esetben  $t_{n-1}$  eloszlású.

- Egyoldali ellenhipotézis esetén legyen  
 $\mathcal{X}_1 = \{x \mid T(x) > F_{t_{n-1}}^{-1}(1 - \alpha)\}$

## Egymintás t-próba

Legyen  $X_1, \dots, X_n$   $n$  elemű minta az  $N(\mu, \sigma^2)$  eloszlásból, ahol most se  $\mu$ -t, se  $\sigma^2$ -et nem ismerjük. Hipotéziseink:

- $H_0: \mu \leq \mu_0, H_1: \mu > \mu_0$  (egyoldali ellenhipotézis).
- $H_0: \mu = \mu_0, H_1: \mu \neq \mu_0$  (kétoldali ellenhipotézis).

$$T(x) = \sqrt{n} \frac{\bar{X} - \mu_0}{s_n^*}$$

Erről a Fisher-Bartlett tétel alapján belátható, hogy  $\mu = \mu_0$  esetben  $t_{n-1}$  eloszlású.

- Egyoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{x \mid T(x) > F_{t_{n-1}}^{-1}(1 - \alpha)\}$
- Kétoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{x \mid |T(x)| > F_{t_{n-1}}^{-1}(1 - \frac{\alpha}{2})\}$

## Kétmintás t-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma^2)$  eloszlásból. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

## Kétmintás t-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma^2)$  eloszlásból. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \sqrt{\frac{n_1 n_2}{n_1 + n_2}} \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(n_1 - 1)s_X^{*2} + (n_2 - 1)s_Y^{*2}}{n_1 + n_2 - 2}}}$$

## Kétmintás t-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma^2)$  eloszlásból. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \sqrt{\frac{n_1 n_2}{n_1 + n_2}} \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(n_1 - 1)s_X^{*2} + (n_2 - 1)s_Y^{*2}}{n_1 + n_2 - 2}}}$$

Erről hosszadalmasan, de belátható, hogy  $\mu_1 = \mu_2$  esetben  $t_{n_1+n_2-2}$  eloszlású.

## Kétmintás t-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma^2)$  eloszlásból. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \sqrt{\frac{n_1 n_2}{n_1 + n_2}} \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(n_1 - 1)s_X^{*2} + (n_2 - 1)s_Y^{*2}}{n_1 + n_2 - 2}}}$$

Erről hosszadalmasan, de belátható, hogy  $\mu_1 = \mu_2$  esetben  $t_{n_1+n_2-2}$  eloszlású.

- Egyoldali ellenhipotézis esetén legyen  
 $\mathcal{X}_1 = \{(x, y) \mid T(x, y) > F_{t_{n_1+n_2-2}}^{-1}(1 - \alpha)\}$

## Kétmintás t-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma^2)$  eloszlásból. Hipotéziseink:

- $H_0: \mu_1 \leq \mu_2, H_1: \mu_1 > \mu_2$  (egyoldali ellenhipotézis).
- $H_0: \mu_1 = \mu_2, H_1: \mu_1 \neq \mu_2$  (kétoldali ellenhipotézis).

$$T(x, y) = \sqrt{\frac{n_1 n_2}{n_1 + n_2}} \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(n_1 - 1)s_X^{*2} + (n_2 - 1)s_Y^{*2}}{n_1 + n_2 - 2}}}$$

Erről hosszadalmasan, de belátható, hogy  $\mu_1 = \mu_2$  esetben  $t_{n_1+n_2-2}$  eloszlású.

- Egyoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{(x, y) \mid T(x, y) > F_{t_{n_1+n_2-2}}^{-1}(1 - \alpha)\}$
- Kétoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{(x, y) \mid |T(x, y)| > F_{t_{n_1+n_2-2}}^{-1}(1 - \frac{\alpha}{2})\}$





# F-eloszlás

Legyen  $X \sim \chi_n^2$ ,  $Y \sim \chi_m^2$  függetlenek.

Ekkor  $Z = \frac{mX}{nY}$  eloszlását  $n, m$  szabadságfokú F-eloszlásnak hívjuk  
( $F_{n,m}$ )

# F-eloszlás



## F-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból. Hipotéziseink:

- $H_0: \sigma_1^2 \leq \sigma_2^2, H_1: \sigma_1^2 > \sigma_2^2$  (egyoldali ellenhipotézis).
- $H_0: \sigma_1^2 = \sigma_2^2, H_1: \sigma_1^2 \neq \sigma_2^2$  (egyoldali ellenhipotézis).

## F-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból. Hipotéziseink:

- $H_0: \sigma_1^2 \leq \sigma_2^2, H_1: \sigma_1^2 > \sigma_2^2$  (egyoldali ellenhipotézis).
- $H_0: \sigma_1^2 = \sigma_2^2, H_1: \sigma_1^2 \neq \sigma_2^2$  (egyoldali ellenhipotézis).

$$T(x) = \frac{s_X^{*2}}{s_Y^{*2}}$$

## F-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból. Hipotéziseink:

- $H_0: \sigma_1^2 \leq \sigma_2^2, H_1: \sigma_1^2 > \sigma_2^2$  (egyoldali ellenhipotézis).
- $H_0: \sigma_1^2 = \sigma_2^2, H_1: \sigma_1^2 \neq \sigma_2^2$  (egyoldali ellenhipotézis).

$$T(x) = \frac{s_X^{*2}}{s_Y^{*2}}$$

Ez  $\mu = \mu_0$  esetben  $F_{n_1-1, n_2-1}$  eloszlású.

## F-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból. Hipotéziseink:

- $H_0: \sigma_1^2 \leq \sigma_2^2, H_1: \sigma_1^2 > \sigma_2^2$  (egyoldali ellenhipotézis).
- $H_0: \sigma_1^2 = \sigma_2^2, H_1: \sigma_1^2 \neq \sigma_2^2$  (egyoldali ellenhipotézis).

$$T(x) = \frac{s_X^{*2}}{s_Y^{*2}}$$

Ez  $\mu = \mu_0$  esetben  $F_{n_1-1, n_2-1}$  eloszlású.

- Egyoldali ellenhipotézis esetén legyen

$$\mathcal{X}_1 = \{(x, y) \mid T(x, y) > F_{F_{n_1-1, n_2-1}}^{-1}(1 - \alpha)\}$$

## F-próba

Legyen  $X$   $n_1$  elemű minta az  $N(\mu_1, \sigma_1^2)$  eloszlásból,  $Y$   $n_2$  elemű minta az  $N(\mu_2, \sigma_2^2)$  eloszlásból. Hipotéziseink:

- $H_0: \sigma_1^2 \leq \sigma_2^2, H_1: \sigma_1^2 > \sigma_2^2$  (egyoldali ellenhipotézis).
- $H_0: \sigma_1^2 = \sigma_2^2, H_1: \sigma_1^2 \neq \sigma_2^2$  (egyoldali ellenhipotézis).

$$T(x) = \frac{s_X^{*2}}{s_Y^{*2}}$$

Ez  $\mu = \mu_0$  esetben  $F_{n_1-1, n_2-1}$  eloszlású.

- Egyoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{(x, y) \mid T(x, y) > F_{F_{n_1-1, n_2-1}}^{-1}(1 - \alpha)\}$
- Kétoldali ellenhipotézis esetén legyen  $\mathcal{X}_1 = \{(x, y) \mid T(x, y) > F_{F_{n_1-1, n_2-1}}^{-1}(1 - \frac{\alpha}{2}) \vee T(x, y) < F_{F_{n_1-1, n_2-1}}^{-1}(\frac{\alpha}{2})\}$

## Illeszkedés-vizsgálat

Legyen  $X$   $n$  elemű minta tetszőleges eloszlásból. Ezeket  $s$  osztályba soroljuk, az  $i$ -edik osztályba  $N_i$  került. Hipotéziseink:

- $H_0$ : az osztályok valószínűségei  $p_1, \dots, p_s$ ,  $H_1$ : nem



## Illeszkedés-vizsgálat

Legyen  $X$   $n$  elemű minta tetszőleges eloszlásból. Ezeket  $s$  osztályba soroljuk, az  $i$ -edik osztályba  $N_i$  került. Hipotéziseink:

- $H_0$ : az osztályok valószínűségei  $p_1, \dots, p_s$ ,  $H_1$ : nem

$$T(x) = \sum_{i=1}^s \frac{(N_i - np_i)^2}{np_i}$$

## Illeszkedés-vizsgálat

Legyen  $X$   $n$  elemű minta tetszőleges eloszlásból. Ezeket  $s$  osztályba soroljuk, az  $i$ -edik osztályba  $N_i$  került. Hipotéziseink:

- $H_0$ : az osztályok valószínűségei  $p_1, \dots, p_s$ ,  $H_1$ : nem

$$T(x) = \sum_{i=1}^s \frac{(N_i - np_i)^2}{np_i}$$

Belátható, hogy ha  $H_0$  teljesül és  $n \rightarrow \infty$ , akkor  $T \rightarrow \chi_{s-1}^2$ .

## Illeszkedés-vizsgálat

Legyen  $X$   $n$  elemű minta tetszőleges eloszlásból. Ezeket  $s$  osztályba soroljuk, az  $i$ -edik osztályba  $N_i$  került. Hipotéziseink:

- $H_0$ : az osztályok valószínűségei  $p_1, \dots, p_s$ ,  $H_1$ : nem

$$T(x) = \sum_{i=1}^s \frac{(N_i - np_i)^2}{np_i}$$

Belátható, hogy ha  $H_0$  teljesül és  $n \rightarrow \infty$ , akkor  $T \rightarrow \chi_{s-1}^2$ .

- $\mathcal{X}_1 = \{x \mid T(x) > F_{\chi_{s-1}^2}^{-1}(1 - \alpha)\}$

## Illeszkedés-vizsgálat

Legyen  $X$   $n$  elemű minta tetszőleges eloszlásból. Ezeket  $s$  osztályba soroljuk, az  $i$ -edik osztályba  $N_i$  került. Hipotéziseink:

- $H_0$ : az osztályok valószínűségei  $p_1, \dots, p_s$ ,  $H_1$ : nem

$$T(x) = \sum_{i=1}^s \frac{(N_i - np_i)^2}{np_i}$$

Belátható, hogy ha  $H_0$  teljesül és  $n \rightarrow \infty$ , akkor  $T \rightarrow \chi_{s-1}^2$ .

- $\mathcal{X}_1 = \{x \mid T(x) > F_{\chi_{s-1}^2}^{-1}(1 - \alpha)\}$

Ez egy nagymintás próba, meg szokták követelni, hogy minden osztályba legalább 4 – 6 megfigyelés legyen. (Osztályokat összevonhatjuk például, ha ez nem teljesül.)

## Becsléses illeszkedés-vizsgálat

A feladat ugyanaz, mint az előbb, csak most  $p_i$ -ket nem tudjuk konkrétan, hanem azok is függnnek egy  $\gamma \in \Gamma \subseteq \mathbb{R}^t$  dimenziós paramétertől.

## Becsléses illeszkedés-vizsgálat

A feladat ugyanaz, mint az előbb, csak most  $p_i$ -ket nem tudjuk konkrétan, hanem azok is függenek egy  $\gamma \in \Gamma \subseteq \mathbb{R}^t$  dimenziós paramétertől.

Ha  $t < s - 1$ , valamint  $p_i$ -k elég szépen függenek  $\gamma$ -tól ( $\gamma \mapsto p(\gamma)$  folytonosan differenciálható és a Jacobi-mátrixának rangja  $t$ ), akkor működik a következő:

## Becsléses illeszkedés-vizsgálat

A feladat ugyanaz, mint az előbb, csak most  $p_i$ -ket nem tudjuk konkrétan, hanem azok is függenek egy  $\gamma \in \Gamma \subseteq \mathbb{R}^t$  dimenziós paramétertől.

Ha  $t < s - 1$ , valamint  $p_i$ -k elég szépen függenek  $\gamma$ -tól ( $\gamma \mapsto p(\gamma)$  folytonosan differenciálható és a Jacobi-mátrixának rangja  $t$ ), akkor működik a következő:

Vegyük  $\gamma$  ML-becslését ( $\hat{\gamma}$ ), és végezzük el az előző dián leírt  $T(x)$  statisztikát a  $p_i(\hat{\gamma})$  valószínűségekkel.

## Becsléses illeszkedés-vizsgálat

A feladat ugyanaz, mint az előbb, csak most  $p_i$ -ket nem tudjuk konkrétan, hanem azok is függenek egy  $\gamma \in \Gamma \subseteq \mathbb{R}^t$  dimenziós paramétertől.

Ha  $t < s - 1$ , valamint  $p_i$ -k elég szépen függenek  $\gamma$ -tól ( $\gamma \mapsto p(\gamma)$  folytonosan differenciálható és a Jacobi-mátrixának rangja  $t$ ), akkor működik a következő:

Vegyük  $\gamma$  ML-becslését ( $\hat{\gamma}$ ), és végezzük el az előző dián leírt  $T(x)$  statisztikát a  $p_i(\hat{\gamma})$  valószínűségekkel.

Ekkor ha igaz a nullhipotézisünk, vagyis ha  $p_i$ -k tényleg  $p_i(\gamma)$  alakúak, akkor  $T \rightarrow \chi_{s-t-1}^2$ , tehát végezhetünk ismét  $\chi^2$ -próbát.



## Homogenitás-vizsgálat

Most legyen két független mintánk  $n$  és  $m$  megfigyeléssel, ugyanabba az  $s$  osztályba soroljuk őket. Az osztályok valószínűségei  $p_i, q_i$ ;  $N_i, M_i$  megfigyelés került beléjük. Hipotéziseink:

- $H_0$ : az osztályok valószínűségeire  $p_1 = q_1, \dots, p_s = q_s$ ,  $H_1$ :  
nem

## Homogenitás-vizsgálat

Most legyen két független mintánk  $n$  és  $m$  megfigyeléssel, ugyanabba az  $s$  osztályba soroljuk őket. Az osztályok valószínűségei  $p_i, q_i$ ;  $N_i, M_i$  megfigyelés került beléjük. Hipotéziseink:

- $H_0$ : az osztályok valószínűségeire  $p_1 = q_1, \dots, p_s = q_s$ ,  $H_1$ :  
nem

$$T = mn \sum_{i=1}^s \frac{\left(\frac{N_i}{n} - \frac{M_i}{m}\right)^2}{N_i + M_i}$$

## Homogenitás-vizsgálat

Most legyen két független mintánk  $n$  és  $m$  megfigyeléssel, ugyanabba az  $s$  osztályba soroljuk őket. Az osztályok valószínűségei  $p_i, q_i$ ;  $N_i, M_i$  megfigyelés került beléjük. Hipotéziseink:

- $H_0$ : az osztályok valószínűségeire  $p_1 = q_1, \dots, p_s = q_s$ ,  $H_1$ : nem

$$T = mn \sum_{i=1}^s \frac{\left( \frac{N_i}{n} - \frac{M_i}{m} \right)^2}{N_i + M_i}$$

Belátható, hogy  $H_0$  esetén  $T \rightarrow \chi_{s-1}^2$ , erre végezzünk  $\chi^2$ -próbát.

## Függetlenség-vizsgálat

Van  $n$  megfigyelésünk, két szempont szerint osztályozzuk ezeket. Az első szerint  $s$ , a második szerint  $t$  osztályba osztjuk.  $N_{ij}$  elem került az  $(i, j)$  osztályba, az osztály valószínűsége  $p_{ij}$ .

Jelölés:  $N_{i.} = \sum_{j=1}^t N_{ij}$ ,  $N_{.j} = \sum_{i=1}^s N_{ij}$

Hipotéziseink:

- $H_0$ : a két szempont független, azaz  $\forall i, j$ -re  $p_{ij} = p_{i.}p_{.j}$ ,  $H_1$ : nem

## Függetlenség-vizsgálat

Van  $n$  megfigyelésünk, két szempont szerint osztályozzuk ezeket. Az első szerint  $s$ , a második szerint  $t$  osztályba osztjuk.  $N_{ij}$  elem került az  $(i, j)$  osztályba, az osztály valószínűsége  $p_{ij}$ .

Jelölés:  $N_{i.} = \sum_{j=1}^t N_{ij}$ ,  $N_{.j} = \sum_{i=1}^s N_{ij}$

Hipotéziseink:

- $H_0$ : a két szempont független, azaz  $\forall i, j$ -re  $p_{ij} = p_{i.} \cdot p_{.j}$ ,  $H_1$ : nem

$$T = n \left( \sum_{i=1}^s \sum_{j=1}^t \frac{N_{ij}^2}{N_{i.} \cdot N_{.j}} - 1 \right)$$

## Függetlenség-vizsgálat

Van  $n$  megfigyelésünk, két szempont szerint osztályozzuk ezeket. Az első szerint  $s$ , a második szerint  $t$  osztályba osztjuk.  $N_{ij}$  elem került az  $(i, j)$  osztályba, az osztály valószínűsége  $p_{ij}$ .

Jelölés:  $N_{i.} = \sum_{j=1}^t N_{ij}$ ,  $N_{.j} = \sum_{i=1}^s N_{ij}$

Hipotéziseink:

- $H_0$ : a két szempont független, azaz  $\forall i, j$ -re  $p_{ij} = p_{i.} \cdot p_{.j}$ ,  $H_1$ : nem

$$T = n \left( \sum_{i=1}^s \sum_{j=1}^t \frac{N_{ij}^2}{N_{i.} \cdot N_{.j}} - 1 \right)$$

Belátható, hogy  $H_0$  esetén  $T \rightarrow \chi_{(s-1)(t-1)}^2$ , erre végezzünk  $\chi^2$ -próbát.

## Példa

1875-1894 között 10 porosz hadtestnél a lórúgás általi halálesetek száma (1 adat/hadtest/év):

halálesetek száma	0	1	2	3	4
gyakoriság	109	65	22	3	1

## Példa

1875-1894 között 10 porosz hadtestnél a lórúgás általi halálesetek száma (1 adat/hadtest/év):

halálesetek száma	0	1	2	3	4
gyakoriság	109	65	22	3	1

Hipotézis: A halálesetek száma egy év alatt egy hadtestben Poisson-eloszlású.  
Hogyan kell ellenőrizni?



## Példa

1875-1894 között 10 porosz hadtestnél a lórúgás általi halálesetek száma (1 adat/hadtest/év):

halálesetek száma	0	1	2	3	4
gyakoriság	109	65	22	3	1

Hipotézis: A halálesetek száma egy év alatt egy hadtestben Poisson-eloszlású.

Hogyan kell ellenőrizni?

Becsléses illeszkedésvizsgálat

## Példa

Utolsó két oszlopot összevonjuk, mert túl kicsik:

halálesetek száma	0	1	2	$\geq 3$
gyakoriság	109	65	22	4

## Példa

Utolsó két oszlopot összevonjuk, mert túl kicsik:

halálesetek száma	0	1	2	$\geq 3$
gyakoriság	109	65	22	4

Tehát azt szeretnénk belátni, hogy  $\text{Poisson}(\lambda)$  az eloszlásunk.

## Példa

Utolsó két oszlopot összevonjuk, mert túl kicsik:

halálesetek száma	0	1	2	$\geq 3$
gyakoriság	109	65	22	4

Tehát azt szeretnénk belátni, hogy  $\text{Poisson}(\lambda)$  az eloszlásunk. Ehhez először  $\lambda$ -ra kell ML-becslést adnunk ( $\hat{\lambda}$ ), majd illeszkedéses  $\chi^2$ -próbát kell végeznünk, és remélhetőleg  $\chi^2_2$  eloszlást kapunk.

## Poisson eloszlás paraméterének ML-becslése

Emlékeztetőül, ha  $X \sim \text{Poisson}(\lambda)$ , akkor:

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

## Poisson eloszlás paraméterének ML-becslése

Emlékeztetőül, ha  $X \sim \text{Poisson}(\lambda)$ , akkor:

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

Ha  $n$  elemű mintánk van, akkor a likelihood-függvényünk (aminek a maximumát keressük):

$$L(\lambda \mid x) = \prod_{i=1}^n P(X_i = x_i) = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} e^{-\lambda} = e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i} \prod_{i=1}^n \frac{1}{x_i!}$$

## Poisson eloszlás paraméterének ML-becslése

Emlékeztetőül, ha  $X \sim \text{Poisson}(\lambda)$ , akkor:

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

Ha  $n$  elemű mintánk van, akkor a likelihood-függvényünk (aminek a maximumát keressük):

$$L(\lambda | x) = \prod_{i=1}^n P(X_i = x_i) = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} e^{-\lambda} = e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i} \prod_{i=1}^n \frac{1}{x_i!}$$

Logaritmusa:

$$l(\lambda | x) = -n\lambda + \ln \lambda \sum_{i=1}^n x_i + c(x) = -n\lambda + n\bar{x} \ln \lambda + c(x)$$

## Poisson eloszlás paraméterének ML-beclése

Emlékeztetőül, ha  $X \sim \text{Poisson}(\lambda)$ , akkor:

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

Ha  $n$  elemű mintánk van, akkor a likelihood-függvényünk (aminek a maximumát keressük):

$$L(\lambda | x) = \prod_{i=1}^n P(X_i = x_i) = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} e^{-\lambda} = e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i} \prod_{i=1}^n \frac{1}{x_i!}$$

Logaritmusa:

$$l(\lambda | x) = -n\lambda + \ln \lambda \sum_{i=1}^n x_i + c(x) = -n\lambda + n\bar{x} \ln \lambda + c(x)$$

Deriváljuk  $\lambda$  szerint:

$$-n + \frac{n\bar{x}}{\hat{\lambda}} = 0 \implies \hat{\lambda} = \bar{x}$$



## Példa

Kiszámoljuk az átlagot:

$$\hat{\lambda} = \bar{X} = \frac{109 \cdot 0 + 65 \cdot 1 + 22 \cdot 2 + 3 \cdot 3 + 4 \cdot 1}{200} = \frac{122}{200} = 0.61$$

## Példa

Kiszámoljuk az átlagot:

$$\hat{\lambda} = \bar{X} = \frac{109 \cdot 0 + 65 \cdot 1 + 22 \cdot 2 + 3 \cdot 3 + 4 \cdot 1}{200} = \frac{122}{200} = 0.61$$

halálesetek száma ( $i$ )	0	1	2	$\geq 3$	összeg
gyakoriság ( $N_i$ )	109	65	22	4	200
valószínűség ( $p_i$ )	0.54	0.33	0.10	0.03	1.00
várt gyakoriság ( $np_i$ )	108	66	20	6	200
eltérés ( $N_i - np_i$ )	1	-1	2	-2	0
$\frac{(N_i - np_i)^2}{np_i}$	0.01	0.02	0.20	0.67	0.90

## Példa

Kiszámoljuk az átlagot:

$$\hat{\lambda} = \bar{X} = \frac{109 \cdot 0 + 65 \cdot 1 + 22 \cdot 2 + 3 \cdot 3 + 4 \cdot 1}{200} = \frac{122}{200} = 0.61$$

halálesetek száma ( $i$ )	0	1	2	$\geq 3$	összeg
gyakoriság ( $N_i$ )	109	65	22	4	200
valószínűség ( $p_i$ )	0.54	0.33	0.10	0.03	1.00
várt gyakoriság ( $np_i$ )	108	66	20	6	200
eltérés ( $N_i - np_i$ )	1	-1	2	-2	0
$\frac{(N_i - np_i)^2}{np_i}$	0.01	0.02	0.20	0.67	0.90

$T(X) = 0.90$  jött ki, azt tudjuk, hogy ha a hipotézisünk igaz, akkor  $T \approx \chi_2^2$ . Mit jelent ez?

Köszönöm a figyelmet!