

# Becslések és tulajdonságaik (11. előadás)

- $(\Omega, \mathcal{A}, \mathcal{P})$  statisztikai mező;
- $\mathcal{P} = \{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$  valamely  $\Theta$  halmazzal ( $\Theta$  a paramétertér);
- $\psi : \Theta \rightarrow \mathbb{R}$  függvény.
- Cél: olyan  $T$  statisztika keresése, amire a  $T(X)$  valószínűségi változó és a  $\psi(\vartheta)$  érték valamilyen értelemben közel esnek egymáshoz.

# Becslések és tulajdonságaik (11. előadás)

- $(\Omega, \mathcal{A}, \mathcal{P})$  statisztikai mező;
- $\mathcal{P} = \{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$  valamely  $\Theta$  halmazzal ( $\Theta$  a paramétertér);
- $\psi : \Theta \rightarrow \mathbb{R}$  függvény.
- Cél: olyan  $T$  statisztika keresése, amire a  $T(X)$  valószínűségi változó és a  $\psi(\vartheta)$  érték valamilyen értelemben közel esnek egymáshoz.

## Definíció (Torzítatlanság)

A  $T$  statisztika torzítatlan becslés  $\psi$ -re, ha minden  $\vartheta \in \Theta$ -ra

$$\mathbb{E}_\vartheta(T(X_1, \dots, X_n)) = \psi(\vartheta).$$

A  $T$  statisztika torzítása a  $b_T(\vartheta) = \mathbb{E}_\vartheta(T(X_1, \dots, X_n)) - \psi(\vartheta)$  függvény.

**Példa.**  $X_1, X_2, \dots, X_n$  független minta a  $[0, \vartheta]$  intervallumon egyenletes eloszlásból. Ekkor  $2\bar{X}$  torzítatlan becslés  $\psi(\vartheta) = \vartheta$ -ra.

# Torzítatlan becslések

## Állítás (A várható érték torzítatlan becslése)

Legyen  $X_1, \dots, X_n$  független azonos eloszlású véges várható értékű minta. Ekkor

$$\mathbb{E}_{\vartheta}(\bar{X}) = \mathbb{E}_{\vartheta}(X_1) \quad \text{minden } \vartheta \in \Theta\text{-ra,}$$

vagyis a **mintaátlag** torzítatlan becslés  $\psi$ -re.

## Állítás (A szórásnégyzet torzítatlan becslése)

$X_1, \dots, X_n$  független azonos eloszlású véges szórású minta. Ekkor Ekkor

$$\mathbb{E}_{\vartheta}(s_n^{*2}) = D_{\vartheta}^2(X_1) \quad \text{minden } \vartheta \in \Theta\text{-ra,}$$

vagyis a **korrigált tapasztalati szórásnégyzet** torzítatlan becslés a szórásnégyzet-re.

Bizonyításvázlat a következő oldalakon.

# Az átlag várható értéke

## Állítás

Legyen  $X_1, \dots, X_n$  független azonos eloszlású minta, és  $m = \mathbb{E}(X_i) < \infty$ . Ekkor

$$\mathbb{E}(\bar{X}) = m.$$

# Az átlag várható értéke

## Állítás

Legyen  $X_1, \dots, X_n$  független azonos eloszlású minta, és  $m = \mathbb{E}(X_i) < \infty$ . Ekkor

$$\mathbb{E}(\bar{X}) = m.$$

## Bizonyítás.

$$\mathbb{E}(\bar{X}) = \mathbb{E}\left(\frac{X_1 + \dots + X_n}{n}\right) = \frac{1}{n}\mathbb{E}(X_1 + \dots + X_n) = \frac{1}{n} \cdot nm = m.$$

Felhasználtuk a várható érték linearitását, és hogy csak eloszlástól függ:

- $\mathbb{E}(cX) = c\mathbb{E}(X)$ , ha  $c \in \mathbb{R}$ ;
- $\mathbb{E}(Y + Z) = \mathbb{E}(Y) + \mathbb{E}(Z)$ ;
- ha  $Y$  és  $Z$  eloszlása megegyezik, akkor  $\mathbb{E}(Y) = \mathbb{E}(Z)$

Tehát a **mintaátlag** torzítatlan becslés a várható értékre.

# Az átlag szórása

## Állítás

Legyen  $X_1, \dots, X_n$  független azonos eloszlású minta, és  $\mathbb{E}(X_i^4) < \infty$ . Ekkor

$$D(\bar{X}) = \frac{D(X_1)}{\sqrt{n}}.$$

# Az átlag szórása

## Állítás

Legyen  $X_1, \dots, X_n$  független azonos eloszlású minta, és  $\mathbb{E}(X_i^4) < \infty$ . Ekkor

$$D(\bar{X}) = \frac{D(X_1)}{\sqrt{n}}.$$

## Bizonyítás.

$$D(\bar{X}) = D\left(\frac{X_1 + \dots + X_n}{n}\right) = \frac{D(X_1 + \dots + X_n)}{n} = \frac{\sqrt{n\sigma^2}}{n} = \frac{\sigma}{\sqrt{n}}.$$

Felhasználtuk a szórás alábbi tulajdonságait:

- $D(cX) = |c|D(X)$ , ha  $c \in \mathbb{R}$ ;
- $D^2(Y + Z) = D^2(Y) + D^2(Z)$ , ha  $Y$  és  $Z$  függetlenek;
- ha  $Y$  és  $Z$  eloszlása megegyezik, akkor  $D(Y) = D(Z)$

## A tapasztalati szórásnégyzet

Állítás (A tapasztalati szórásnégyzet másik alakja)

$$s_n^2 = \frac{1}{n} \left[ \sum_{k=1}^n X_k^2 \right] - \bar{X}^2.$$

**Bizonyítás.** Átrendezéssel kapjuk, hogy

$$\begin{aligned} \sum_{k=1}^n (X_k - \bar{X})^2 &= \sum_{k=1}^n [X_k^2 - 2X_k \cdot \bar{X} + \bar{X}^2] = \sum_{k=1}^n X_k^2 - 2n\bar{X} \cdot \bar{X} + n \cdot \bar{X}^2 = \\ &= \sum_{k=1}^n X_k^2 - n \cdot \bar{X}^2. \end{aligned}$$

Ebből adódik, hogy

$$s_n^2 = \frac{1}{n} \left[ \sum_{k=1}^n (X_k - \bar{X})^2 \right] = \frac{1}{n} \left[ \sum_{k=1}^n X_k^2 \right] - \bar{X}^2,$$

a tapasztalati szórásnégyzet definíciója alapján.

## A korrigált tapasztalati szórásnégyzet

$$s_n^{*2} = \frac{n}{n-1} s_n^2 = \frac{n}{n-1} \left[ \frac{1}{n} \left[ \sum_{k=1}^n X_k^2 \right] - \bar{X}^2 \right] = \frac{1}{n-1} \left[ \sum_{k=1}^n X_k^2 \right] - \frac{n}{n-1} \bar{X}^2.$$

Az első tag várható értéke a szórásnégyzet definíciója alapján:

$$\mathbb{E}_\vartheta \left( \sum_{k=1}^n X_k^2 \right) = \sum_{k=1}^n \mathbb{E}_\vartheta (X_k^2) = n \cdot \mathbb{E}_\vartheta (X_1^2) = n \cdot [D_\vartheta^2(X_1) + \mathbb{E}_\vartheta (X_1)^2].$$

A második tag várható értéke az átlag szórásnégyzete alapján:

$$\mathbb{E}_\vartheta (\bar{X}^2) = D_\vartheta^2(\bar{X}^2) + \mathbb{E}_\vartheta (\bar{X})^2 = \frac{1}{n} D_\vartheta^2(X_1) + \mathbb{E}_\vartheta (X_1)^2.$$

Vagyis valóban  $s_n^{*2}$  torzítatlan becslés a szórásnégyzetre:

$$\mathbb{E}_\vartheta (s_n^{*2}) = \frac{n}{n-1} [D_\vartheta^2(X_1) + \mathbb{E}_\vartheta (X_1)^2] - \frac{n}{n-1} \left[ \frac{1}{n} D_\vartheta^2(X_1) + \mathbb{E}_\vartheta (X_1)^2 \right] = D_\vartheta^2(X_1).$$

# Becslések összehasonlítása

## Definíció (Hatásosság)

Legyenek  $T_1, T_2$  **torzítatlan** becslései a paraméter  $\psi(\vartheta)$  függvényének.  $T_1$  **hatásosabb**  $T_2$ -nél, ha

$$D_{\vartheta}^2(T_1) \leq D_{\vartheta}^2(T_2)$$

teljesül minden  $\vartheta \in \Theta$ -ra.

A  $T_1$  becslés **hatásos**  $\psi(\vartheta)$ -ra, ha  $\psi(\vartheta)$  minden torzítatlan becslésénél hatásosabb (és ő maga is torzítatlan).

# Becslések összehasonlítása

## Definíció (Hatásosság)

Legyenek  $T_1, T_2$  **torzítatlan** becslései a paraméter  $\psi(\vartheta)$  függvényének.  $T_1$  **hatásosabb**  $T_2$ -nél, ha

$$D_{\vartheta}^2(T_1) \leq D_{\vartheta}^2(T_2)$$

teljesül minden  $\vartheta \in \Theta$ -ra.

A  $T_1$  becslés **hatásos**  $\psi(\vartheta)$ -ra, ha  $\psi(\vartheta)$  minden torzítatlan becslésénél hatásosabb (és ő maga is torzítatlan).

- Nem mindig létezik hatásos becslés, és lehetséges, hogy  $T_1$  és  $T_2$  közül egyik sem hatásosabb a másiknál.
- A várható értékre nézve a mintaátlag hatásosabb minden  $\sum_{j=1}^n c_j X_j$  alakú becslésnél (ahol  $\sum_{j=1}^n c_j = 1$ ).

# Becslések összehasonlítása

## Definíció (Hatásosság)

Legyenek  $T_1, T_2$  **torzítatlan** becslései a paraméter  $\psi(\vartheta)$  függvényének.  $T_1$  **hatásosabb**  $T_2$ -nél, ha


$$D_{\vartheta}^2(T_1) \leq D_{\vartheta}^2(T_2)$$

teljesül minden  $\vartheta \in \Theta$ -ra.

A  $T_1$  becslés **hatásos**  $\psi(\vartheta)$ -ra, ha  $\psi(\vartheta)$  minden torzítatlan becslésénél hatásosabb (és ő maga is torzítatlan).


- Nem mindig létezik hatásos becslés, és lehetséges, hogy  $T_1$  és  $T_2$  közül egyik sem hatásosabb a másiknál.
- A várható értékre nézve a mintaátlag hatásosabb minden  $\sum_{j=1}^n c_j X_j$  alakú becslésnél (ahol  $\sum_{j=1}^n c_j = 1$ ).
- **Bizonyos feladatokban lehet a mintaátlagnál hatásosabb becslés a várható értékre:** A  $[0, b]$  intervallumon egyenletes eloszlás esetén  $b$ -re  $\frac{n+1}{n} \max(X_1, \dots, X_n)$  hatásosabb a mintaátlag kétszeresénél.

# Konzisztens becslés



$\lambda = 0,5$  paraméterű exponenciális eloszlást generálva a mintaátlag reciproka  $0,5$ -höz tart, azaz **konzisztens** becslés, hiszen ez minden  $\lambda$ -ra teljesül.

# Konzisztens becslés



$\lambda = 1$  paraméterű exponenciális eloszlást generálva a mintaátlag reciproka 1-hez tart, azaz **konzisztens** becslés, hiszen ez minden  $\lambda$ -ra teljesül.

# Konzisztencia

## Definíció

A  $T_n = T_n(X_1, \dots, X_n)$  **konzisztens** becsléssorozat  $\psi(\vartheta)$ -ra, ha minden  $\vartheta \in \Theta$ -ra

$$(T_n(X_1, \dots, X_n)) \rightarrow \psi(\vartheta)$$

$n \rightarrow \infty$  esetén sztochasztikusan, azaz minden  $\vartheta \in \Theta$  és  $\varepsilon > 0$ -ra teljesül, hogy

$$\mathbb{P}_\vartheta(|T_n - \psi(\vartheta)| > \varepsilon) \rightarrow 0 \quad (n \rightarrow \infty).$$

# Konzisztencia

## Definíció

A  $T_n = T_n(X_1, \dots, X_n)$  **konzisztens** becsléssorozat  $\psi(\vartheta)$ -ra, ha minden  $\vartheta \in \Theta$ -ra

$$(T_n(X_1, \dots, X_n)) \rightarrow \psi(\vartheta)$$

$n \rightarrow \infty$  esetén sztochasztikusan, azaz minden  $\vartheta \in \Theta$  és  $\varepsilon > 0$ -ra teljesül, hogy

$$\mathbb{P}_\vartheta(|T_n - \psi(\vartheta)| > \varepsilon) \rightarrow 0 \quad (n \rightarrow \infty).$$

Elégséges feltétel:

$$\mathbb{E}_\vartheta(T(X)) \rightarrow \vartheta \quad \text{és} \quad D_\vartheta(T(X)) \rightarrow 0$$

minden  $\vartheta \in \Theta$ -ra.

## Példák torzítatlan, konzisztens becslésekre

$X_1, X_2, \dots$  független azonos eloszlású minta. Ekkor

$$T_n = \frac{X_1 + X_2 + \dots + X_n}{n} \rightarrow \mathbb{E}_\theta(X_1)$$

teljesül  $n \rightarrow \infty$  esetén sztochasztikusan a nagy számok gyenge törvénye szerint, vagyis az **átlag** konzisztens becslés a **várható értékre**.

Speciális eset: a **relatív gyakoriság** konzisztens becslés a **valószínűsége**re.

## Példák torzítatlan, konzisztens becslésekre

$X_1, X_2, \dots$  független azonos eloszlású minta. Ekkor

$$T_n = \frac{X_1 + X_2 + \dots + X_n}{n} \rightarrow \mathbb{E}_\theta(X_1)$$


teljesül  $n \rightarrow \infty$  esetén sztochasztikusan a nagy számok gyenge törvénye szerint, vagyis az **átlag** konzisztens becslés a **várható értékre**.

Speciális eset: a **relatív gyakoriság** konzisztens becslés a **valószínűsége**.

Nevezetes eloszlások:


- Poisson-eloszlás  $\lambda$  paraméterére az átlag torzítatlan, konzisztens
- a normális eloszlás  $m$  paraméterére az átlag torzítatlan és konzisztens; a  $\sigma$  paraméterre a tapasztalati szórás és a korrigált tapasztalati szórás konzisztensek, de nem torzítatlanok;  $\sigma^2$ -re  $s_n^{*2}$  torzítatlan
- exponenciális eloszlás:  $1/\bar{X}$  konzisztens  $\lambda$ -ra, de nem torzítatlan a paraméterre
- exponenciális eloszlás:  $n \cdot \min(X_1, \dots, X_n)$  torzítatlan, de nem konzisztens a várható értékre (vagyis  $1/\lambda$ -ra).

# Poisson-eloszlás paraméterének becslése



A gólok számának hisztogramja  $n = 95$  mérkőzésen, és különböző paraméterű Poisson-eloszlások ( $\mathbb{P}_\lambda(X = k) = \lambda^k / k! \cdot e^{-\lambda}$ )

# Geometriai eloszlás paraméterének becslése



Egy háztartásban élők számának hisztogramja (forrás: KSH, 2011) és a geometriai eloszlás  $p = 0,423$  (piros),  $p = 0,3$  (fekete), és  $p = 0,6$  (kék) paraméterekkel

$n = 4105698$  a háztartások száma,  $1/\bar{X} = 0,423$ ;  $\mathbb{P}_p(X = k) = (1 - p)^{k-1} \cdot p$ .

# Maximumlikelihood-módszer

## Definíció (Likelihood-függvény)

Ha az  $(Y_1, \dots, Y_n)$  független minta diszkrét (a lehetséges értékeinek száma véges vagy megszámlálható sok), akkor a likelihood-függvénye:

$$L_{n,\vartheta}(k_1, \dots, k_n) = \prod_{j=1}^n \mathbb{P}_{j,\vartheta}(Y_j = k_j) \quad ((k_1, \dots, k_n) \in H).$$

# Maximumlikelihood-módszer

## Definíció (Likelihood-függvény)

Ha az  $(Y_1, \dots, Y_n)$  független minta diszkrét (a lehetséges értékeinek száma véges vagy megszámlálható sok), akkor a likelihood-függvénye:

$$L_{n,\vartheta}(k_1, \dots, k_n) = \prod_{j=1}^n \mathbb{P}_{j,\vartheta}(Y_j = k_j) \quad ((k_1, \dots, k_n) \in H).$$

Ha az  $(Y_1, \dots, Y_n)$  független minta abszolút folytonos, és  $Y_j$  sűrűségfüggvénye (a  $\mathbb{P}_\vartheta$  valószínűség mellett)  $f_{j,\vartheta}$ , akkor a minta likelihood-függvénye:

$$L_{n,\vartheta}(t_1, \dots, t_n) = \prod_{j=1}^n f_{j,\vartheta}(t_j) \quad (t_1, \dots, t_n \in \mathbb{R}).$$

# Maximumlikelihood-módszer

Legyen  $(\Omega, \mathcal{A}, \mathbb{P})$  statisztikai mező, ahol  $\mathcal{P} = \{\mathbb{P}_\vartheta : \vartheta \in \Theta\}$ , vagyis az ismeretlen eloszlás a  $\vartheta$  paraméterrel jellemezhető.

## Definíció (Maximum-likelihood becslés)

A  $\vartheta$  maximumlikelihood-becslése (ML-becslése) az  $X_1, \dots, X_n$  mintából  $\hat{\vartheta}$ , ha maximalizálja a  $\vartheta \mapsto L_{n,\vartheta}(X_1, \dots, X_n)$  függvényt, ahol  $L_{n,\vartheta}$  a minta likelihood-függvénye. Azaz, ha

$$L_{n,\hat{\vartheta}}(X_1, \dots, X_n) \geq L_{n,\vartheta}(X_1, \dots, X_n) \text{ minden } \vartheta \in \Theta\text{-ra.}$$

**Példa.**  $X_1, \dots, X_n$  függetlenek, eloszlásuk exponenciális eloszlás  $\vartheta > 0$  paraméterrel. Ekkor

$$L_{n,\vartheta}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[ \vartheta \exp(-\vartheta X_j) \mathbb{I}(X_j > 0) \right],$$

amiből  $\hat{\vartheta} = \frac{1}{\bar{X}}$ .

## Poisson-eloszlás paraméterének becslése

Tegyük fel, hogy  $X_1, X_2, \dots, X_n$  független, azonos  $\lambda$  paraméterű Poisson-eloszlású minta, ahol  $\lambda > 0$  ismeretlen paraméter,  $n = 95$ , és  $\bar{X} = 1,379$ .

Poisson-eloszlásnál:

$$\mathbb{P}_\lambda(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda}; \quad \mathbb{E}(X_j) = \lambda; \quad D(X_j) = \sqrt{\lambda}.$$


A megfigyelések az alábbiak (a gólok száma összesen  $\sum_{j=1}^n X_j = 131$ ):

$$3, \quad 0, \quad 2, \quad 2, \quad 1, \quad 3, \dots, 2.$$

Annak valószínűsége  $\lambda$  paraméter mellett, hogy éppen ezt a sorozatot kaptuk:

$$\begin{aligned} L_{95,\lambda}(3, 0, 2, \dots, 2) &= \frac{\lambda^3}{3!} e^{-\lambda} \cdot \frac{\lambda^0}{0!} e^{-\lambda} \cdot \frac{\lambda^2}{2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^2}{2!} e^{-\lambda} = \\ &= \frac{\lambda^{3+0+2+2\dots+2}}{3! \cdot 0! \cdot 2! \cdot \dots \cdot 2!} e^{-95 \cdot \lambda} = \frac{\lambda^{131}}{3! \cdot 0! \cdot 2! \cdot \dots \cdot 2!} e^{-95 \cdot \lambda} \end{aligned}$$

# Poisson-eloszlás paraméterének becslése



A  $\frac{\lambda^{131}}{3! \cdot 0! \cdot 2! \cdot \dots \cdot 2!} e^{-95 \cdot \lambda}$  likelihoodfüggvény a  $\lambda > 0$  paraméter függvényében;

mintaátlag:  $\bar{X} = \frac{131}{95} = 1,379$

## ML-becslés: Poisson-eloszlás

$X_1, \dots, X_n$  függetlenek, Poisson-eloszlás  $\lambda > 0$  ismeretlen paraméterrel, azaz

$$\mathbb{P}(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad (k = 0, 1, 2, \dots).$$

Ekkor

$$L_{n,\lambda}(X_1, \dots, X_n) = \prod_{j=1}^n \left( \frac{\lambda^{X_j}}{X_j!} e^{-\lambda} \right) = \frac{\lambda^{X_1}}{X_1!} e^{-\lambda} \cdot \frac{\lambda^{X_2}}{X_2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^{X_n}}{X_n!} e^{-\lambda}.$$

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^{\sum_{j=1}^n X_j} e^{-n\lambda} \cdot \prod_{j=1}^n \frac{1}{X_j!}.$$

## ML-becslés: Poisson-eloszlás

$X_1, \dots, X_n$  függetlenek, Poisson-eloszlás  $\lambda > 0$  ismeretlen paraméterrel, azaz

$$\mathbb{P}(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad (k = 0, 1, 2, \dots).$$

Ekkor

$$L_{n,\lambda}(X_1, \dots, X_n) = \prod_{j=1}^n \left( \frac{\lambda^{X_j}}{X_j!} e^{-\lambda} \right) = \frac{\lambda^{X_1}}{X_1!} e^{-\lambda} \cdot \frac{\lambda^{X_2}}{X_2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^{X_n}}{X_n!} e^{-\lambda}.$$

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^{\sum_{j=1}^n X_j} e^{-n\lambda} \cdot \prod_{j=1}^n \frac{1}{X_j!}.$$

$$\log L_{n,\lambda}(X_1, \dots, X_n) = \log \lambda \sum_{j=1}^n X_j - n\lambda + \log \prod_{j=1}^n \frac{1}{X_j!}$$

## ML-becslés: Poisson-eloszlás

$X_1, \dots, X_n$  függetlenek, Poisson-eloszlás  $\lambda > 0$  ismeretlen paraméterrel, azaz

$$\mathbb{P}(X_j = k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad (k = 0, 1, 2, \dots).$$

Ekkor

$$L_{n,\lambda}(X_1, \dots, X_n) = \prod_{j=1}^n \left( \frac{\lambda^{X_j}}{X_j!} e^{-\lambda} \right) = \frac{\lambda^{X_1}}{X_1!} e^{-\lambda} \cdot \frac{\lambda^{X_2}}{X_2!} e^{-\lambda} \cdot \dots \cdot \frac{\lambda^{X_n}}{X_n!} e^{-\lambda}.$$

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^{\sum_{j=1}^n X_j} e^{-n\lambda} \cdot \prod_{j=1}^n \frac{1}{X_j!}.$$

$$\log L_{n,\lambda}(X_1, \dots, X_n) = \log \lambda \sum_{j=1}^n X_j - n\lambda + \log \prod_{j=1}^n \frac{1}{X_j!}$$

$$\frac{\partial}{\partial \lambda} \log L_{n,\lambda}(X_1, \dots, X_n) = \frac{\sum_{j=1}^n X_j}{\lambda} - n > 0 \Leftrightarrow \lambda < \bar{X}.$$

Ezért az ML-becslés:  $\hat{\lambda} = \bar{X}$ . A log monoton növekedését használtuk.