


Poisson-eloszlás paraméterének becslése (4. előadás)



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

Poisson-eloszlás paraméterének becslése

Tegyük fel, hogy X_1, X_2, \dots, X_n független, azonos λ 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 λ 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: $\bar{X} = \frac{131}{95} = 1,379$

Poisson-eloszlás paraméterének becslése



A $\log \frac{\lambda^{131}}{3! \cdot 0! \cdot 2! \cdot \dots \cdot 2!} e^{-95 \cdot \lambda}$ loglikelihoodfüggvény 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

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

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

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

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

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

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

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

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

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

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}_ϑ 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 ϑ paraméterrel jellemezhető.

Definíció (Maximum-likelihood becslés)

A ϑ 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

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

Házi feladat március 4., 8:15-ig: megoldás

Tegyük fel, hogy egy véletlenszerűen kiválasztott ismerős által az utóbbi egy hónapban nézett sorozatok száma **geometriai eloszlású**, a paraméter, $p > 0$ ismeretlen.

A rendelkezésre álló 25 elemű mintára vonatkozóan írjuk fel a likelihood-függvény képletét, és ábrázoljuk is ezt a függvényt.

Határozzuk meg a p paraméter maximumlikelihood-becslését (a konkrét adatokból), azaz azt a \hat{p} -t, amire a likelihoodfüggvény a legnagyobb (elég az ábra alapján).

Házi feladat március 4., 8:15-ig: megoldás

A minta: X_1, X_2, \dots, X_n . Geometriai eloszlás: $\mathbb{P}(Y = k) = (1 - p)^{k-1}p$. A likelihood-függvény:

$$L_{n,p}(X_1, \dots, X_n) = \prod_{j=1}^n ((1 - p)^{X_j-1}p) = (1 - p)^{\sum_{j=1}^n (X_j-1)} p^n.$$

Loglikelihood-függvény:

$$\log L_{n,p} = (n\bar{X} - n) \log(1 - p) + n \log p.$$

Ennek deriváltja:

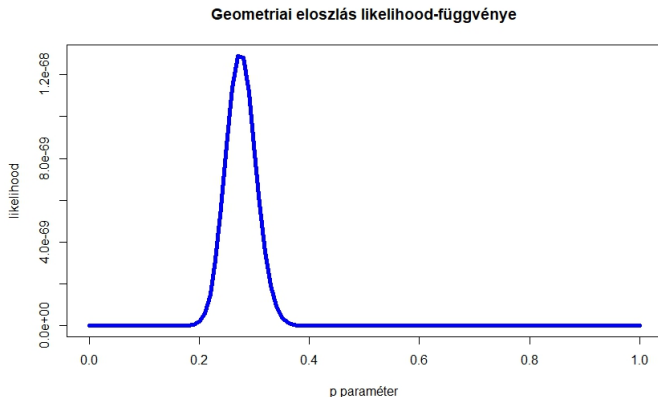
$$\frac{\partial}{\partial p} \log L_{n,p} = -\frac{n(\bar{X} - 1)}{1 - p} + \frac{n}{p} > 0 \Leftrightarrow (1 - p) > p(\bar{X} - 1) \Leftrightarrow p < \frac{1}{\bar{X}}.$$

Ebből következik, hogy a maximumlikelihood-becslés az átlag reciproka:

$$\hat{p} = \frac{1}{\bar{X}}.$$

Emlékeztető: a geometriai eloszlás várható értéke $1/p$.


Házi feladat március 4., 8:15-ig: megoldás



A geometriai eloszlás likelihood-függvénye, ha $n = 73$ ember összesen $\sum_{j=1}^n X_j = 266$ sorozatot nézett, akkor


$$\hat{p} = \frac{1}{\bar{X}} = \frac{73}{266} = 0,27; \quad L_{n,p} = (1 - p)^{266-73} p^{73} = (1 - p)^{193} p^{73}.$$

Házi feladat március 4., 8:15-ig: megoldás




A sorozatok számának hisztogramja és a geometriai eloszlás $\hat{p} = 1/\bar{X} = 0,27$ paraméterrel ($n = 73$ ember, összesen $\sum_{j=1}^n X_j = 266$ sorozatot néztek)

Normális eloszlás sűrűségfüggvénye




Különböző várható értékű és szórású normális eloszlások sűrűségfüggvénye

Testmagasság hisztogramja




A testmagasság hisztogramja $n = 96$ elemű mintából és az $\bar{X} = 174,3$ várható értékű és $s_n^* = 11,5$ szórású normális eloszlás sűrűségfüggvénye (pirossal).

Likelihoodfüggvény



$n = 94$ elemű minta testmagasság-adatok alapján, normális eloszlást feltételezve.
Az átlag: $\bar{X} = 174,8$, a tapasztalati szórás $s_n = 10,5$.

Log-likelihoodfüggvény



$n = 94$ elemű minta testmagasság-adatok alapján, normális eloszlást feltételezve.
Az átlag: $\bar{X} = 174,8$, a tapasztalati szórás $s_n = 10,5$.

ML-becslés: normális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk normális eloszlás $m, \sigma > 0$ paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

ML-becslés: normális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk normális eloszlás $m, \sigma > 0$ paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left(-\sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}\right).$$

ML-becslés: normális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk normális eloszlás $m, \sigma > 0$ paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left(-\sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}\right).$$

$$\log L_{n,m,\sigma}(X_1, \dots, X_n) = -n \log(\sqrt{2\pi}) - n \log \sigma - \sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}.$$

Rögzített σ mellett ez akkor maximális, ha a harmadik tagban $\sum_{j=1}^n (X_j - m)^2 = \sum_{j=1}^n X_j^2 - 2 \sum_{j=1}^n X_j m + nm^2$ minimális $\Rightarrow \hat{m} = \bar{X}$.

ML-becslés: normális eloszlás

$$\log L_{n,\sigma}(X_1, \dots, X_n) = -n \log(\sqrt{2\pi}) - n \log \sigma - \sum_{j=1}^n \frac{(X_j - \bar{X})^2}{2\sigma^2}.$$

A σ szerinti parciális derivált:

$$\frac{\partial}{\partial \sigma} \log L_{n,\sigma}(X_1, \dots, X_n) = -\frac{n}{\sigma} + \sum_{j=1}^n \frac{(X_j - \bar{X})^2}{\sigma^3}.$$

Ez pontosan akkor pozitív, ha $\sigma^2 < \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X})^2 = s_n^2$.

Tehát az ML-becslés:

$$\hat{m} = \bar{X}; \quad \hat{\sigma} = s_n = \sqrt{\frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2}.$$

Tehát normális eloszlásnál az m paraméter becslése a mintaátlag, a szórásé a tapasztalati szórás.

Az ML-becslés tulajdonságai

- Nem minden statisztikai mezőn létezik ML-becslés.
- Az ML-becslés nem feltétlenül egyértelmű.
- Az ML-becslés nem feltétlenül torzítatlan.
- A $\psi(\vartheta)$ függvény ML-becslése $\psi(\hat{\vartheta})$, ahol $\hat{\vartheta}$ ML-becslés ϑ -ra.
- **Megfelelő feltételek** (erős regularitási feltételek mellett) az ML-becslés aszimptotikusan torzítatlan, **aszimptotikusan hatásos** (vagyis minimális szórású) és **aszimptotikusan normális eloszlású**, azaz $\sqrt{n}(\hat{\vartheta}_n - \vartheta)$ normális eloszláshoz konvergál eloszlásban $n \rightarrow \infty$ esetén (a \mathbb{P}_ϑ valószínűségegre vonatkozóan).
- Az alábbi egyenlet a maximumlikelihood-egyenlet:

$$\frac{\partial}{\partial \vartheta} \log L_{n,\vartheta}(X_1, \dots, X_n) = 0.$$

Megfelelő feltételek mellett az ML-becslés a maximumlikelihood-egyenlet megoldása (ha az ML-becslés nem számítható ki, de az egyenlet megoldható, gyakran az egyenlet megoldásával helyettesítik az ML-becslést).

ML-becslés: egyenletes eloszlás

Ebben az esetben az ML-becslés nem számítható ki az ML-egyenlet gyökeként, vagyis nem kapható meg deriválással.

X_1, \dots, X_n függetlenek, eloszlásuk egyenletes eloszlás az $[a, b]$ intervallumon. Ekkor

$$L_{n,a,b}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \mathbb{I}(a \leq X_j \leq b) \cdot \frac{1}{b-a}.$$

$$L_{n,a,b}(X_1, \dots, X_n) = \left(\frac{1}{b-a}\right)^n \mathbb{I}(a \leq \min_j X_j \text{ és } \max_j X_j \leq b).$$

ML-becslés: egyenletes eloszlás

Ebben az esetben az ML-becslés nem számítható ki az ML-egyenlet gyökeként, vagyis nem kapható meg deriválással.

X_1, \dots, X_n függetlenek, eloszlásuk egyenletes eloszlás az $[a, b]$ intervallumon. Ekkor

$$L_{n,a,b}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \mathbb{I}(a \leq X_j \leq b) \cdot \frac{1}{b-a}.$$

$$L_{n,a,b}(X_1, \dots, X_n) = \left(\frac{1}{b-a}\right)^n \mathbb{I}(a \leq \min_j X_j \text{ és } \max_j X_j \leq b).$$

Az első tényező legyen minél nagyobb (vagyis $b - a$ minél kisebb) úgy, hogy a második tényező nem nulla. Ebből:

$$\hat{a} = \min_j X_j; \quad \hat{b} = \max_j X_j.$$

Maximum-likelihood becslések

- binomiális eloszlás ismert k renddel: $\hat{p} = \bar{X}/k$
- Poisson-eloszlás: $\hat{\lambda} = \bar{X}$
- geometriai eloszlás: $\hat{p} = 1/\bar{X}$
- normális eloszlás: $\hat{m} = \bar{X}, \hat{\sigma} = s_n$
- exponenciális eloszlás: $\hat{\lambda} = 1/\bar{X}$
- egyenletes eloszlás: $\hat{a} = \min_j X_j; \quad \hat{b} = \max_j X_j$

ML-becslés: exponenciális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk exponenciális eloszlás $\lambda > 0$ paraméterrel. Ekkor

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

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^n \exp\left(-\lambda \sum_{j=1}^n X_j\right).$$

ML-becslés: exponenciális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk exponenciális eloszlás $\lambda > 0$ paraméterrel. Ekkor

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

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^n \exp\left(-\lambda \sum_{j=1}^n X_j\right).$$

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

ML-becslés: exponenciális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk exponenciális eloszlás $\lambda > 0$ paraméterrel. Ekkor

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

$$L_{n,\lambda}(X_1, \dots, X_n) = \lambda^n \exp\left(-\lambda \sum_{j=1}^n X_j\right).$$

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

$$\frac{\partial}{\partial \lambda} \log L_{n,\lambda}(X_1, \dots, X_n) = \frac{n}{\lambda} - n\bar{X} > 0 \Leftrightarrow \lambda < 1/\bar{X} \Rightarrow \hat{\lambda} = 1/\bar{X}.$$

Momentum módszer

Legyen X_1, \dots, X_n független azonos eloszlású minta.

- 1 Az eloszlás k . momentuma, ha ϑ az ismeretlen paraméter: $\mu_{k,\vartheta} = \mathbb{E}_{\vartheta}(X_1^k)$.
- 2 Legyen $\hat{\mu}_k = \frac{1}{n} \sum_{j=1}^n X_j^k$ az eloszlás k . tapasztalati momentuma.
- 3 Írjuk fel az alábbi egyenleteket a legkisebb olyan k -ig, amire az egyenletrendszer egyértelműen meghatározza ϑ -t (**bár nincs mindig ilyen k**):

$$\mathbb{E}_{\vartheta}(X_1) = \frac{1}{n} \sum_{j=1}^n X_j;$$

$$\mathbb{E}_{\vartheta}(X_1^2) = \frac{1}{n} \sum_{j=1}^n X_j^2;$$

...

$$\mathbb{E}_{\vartheta}(X_1^k) = \frac{1}{n} \sum_{j=1}^n X_j^k.$$

- 4 A ϑ momentum módszerrel kapott becslése az a $\hat{\vartheta}$, ami megoldása a fenti egyenletrendszernek. **Nem mindig létezik, nem mindig egyértelmű, nem feltétlenül hatásos.**

Momentum módszer: Poisson- és exponenciális eloszlás

X_1, \dots, X_n független **Poisson-eloszlásúak** ismeretlen $\lambda > 0$ paraméterrel. A $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \bar{X}.$$

Mivel a λ paraméterű Poisson-eloszlás várható értéke λ :

$$\hat{\lambda} = \bar{X}.$$

Momentum módszer: Poisson- és exponenciális eloszlás

X_1, \dots, X_n független **Poisson-eloszlásúak** ismeretlen $\lambda > 0$ paraméterrel. A $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \bar{X}.$$

Mivel a λ paraméterű Poisson-eloszlás várható értéke λ :

$$\hat{\lambda} = \bar{X}.$$

X_1, \dots, X_n független **exponenciális** eloszlásúak ismeretlen $\lambda > 0$ paraméterrel. A $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \frac{1}{\lambda} = \frac{1}{n} \sum_{j=1}^n X_j = \bar{X}.$$

Ez egyértelműen oldható meg λ -ra:

$$\hat{\lambda} = \frac{1}{\bar{X}}.$$

Momentum módszer: normális eloszlás

X_1, \dots, X_n független $N(m, \sigma^2)$ eloszlású minta (azaz normális eloszlású m várható értékkel és σ szórással).

A $k = 1$ -hez és $k = 2$ -höz tartozó egyenletek:

$$\mathbb{E}_{m,\sigma}(X_1) = m = \bar{X};$$

$$\mathbb{E}_{m,\sigma}(X_1^2) = \sigma^2 + m^2 = \frac{1}{n} \sum_{j=1}^n X_j^2.$$

A másodikba beírva az elsőt: $\sigma^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2 = s_n^2$ (a tapasztalati szórásnégyzet). Tehát az első két egyenlet együtt egyértelműen oldható meg, a momentum módszerrel kapott becslés:

$$\hat{m} = \bar{X}; \quad \hat{\sigma} = s_n.$$

Momentum módszer: egyenletes eloszlás

Legyen X_1, \dots, X_n független minta az $[a, b]$ intervallumon egyenletes eloszlásból. Ennek várható értéke $(a + b)/2$, szórása $(b - a)/\sqrt{12}$. Ezek alapján a $k = 1$ -hez és $k = 2$ -höz tartozó egyenlet:

$$\mathbb{E}_{a,b}(X_1) = \frac{a + b}{2} = \bar{X};$$
$$\mathbb{E}_{a,b}(X_1^2) = \frac{(b - a)^2}{12} + \left(\frac{a + b}{2}\right)^2 = \frac{1}{n} \sum_{j=1}^n X_j^2.$$

A másodikba beírva az elsőt: $\frac{(b-a)^2}{12} = \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2 = s_n^2$, amiből

$$\hat{a} = \bar{X} - \sqrt{3}s_n; \quad \hat{b} = \bar{X} + \sqrt{3}s_n.$$

Hátránya: előfordulhat, hogy ezek nem is lehetséges értékek: ha \hat{a} nagyobb a legkisebb megfigyelésnél, vagy \hat{b} kisebb a legnagyobb megfigyelésnél.

Házi feladat március 11., 8:15-ig

Tekintsünk a (ϑ, ϑ^2) intervallumon egyenletes eloszlású mintát: X_1, X_2, \dots, X_n . Itt $\vartheta > 0$ ismeretlen paraméter. Adjuk meg ϑ momentum módszerrel és maximum-likelihood-módszerrel kapott becslését.

Válasszunk különböző ϑ értékeket (legalább 10-et), és sorsoljunk mindegyikből 100 elemű mintát. Készítsünk táblázatot a ϑ igazi értékével, illetve a mintából kapott két becsléssel az ML, illetve momentum módszer alapján. A táblázat (és esetleg további, ebből számított értékek) alapján hasonlítsuk össze a két módszert (fogalmazzunk meg többféle lehetséges szempontot, ami alapján a két módszer összehasonlítható).