

Elégséges statisztika (5. előadás)

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


Találhatunk-e olyan általános módszereket, melyeket alkalmazva a ϑ ismeretlen paraméter becslésére egy megfelelő $T(X_1, \dots, X_n)$ statisztika

- torzítatlan: várható értéke megegyezik a becslni kívánt ϑ paraméterrel?
- hatásos: szórása a lehető legkisebb?
- konzisztens: a mintaelemszámmal végtelenhez tartva a becsléseink sorozata ϑ -hoz tart: $T_n \rightarrow \vartheta$ sztochasztikusan $n \rightarrow \infty$ esetén?

Ha igen, mi az a **minimális információ a mintából**, amire szükségünk van?

Illetve, mennyire lehet kicsi a szórás, ha a mintából származó információ "mennyisége" adott?

Poisson-eloszlás paraméterének becslése



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

Minta: 0, 2, 1, 2, 4, ...

Házi feladat március 7., 10:30-ig


Tegyük fel, hogy az ismerőseink által az utóbbi két hétben nézett sorozatok száma Poisson-eloszlású, ismeretlen $\lambda > 0$ paraméterrel.

a) Határozzuk meg és ábrázoljuk a likelihood-függvényt, nézzük meg, hol lehet a maximuma.

b) Hasonlítsuk össze a $\hat{\lambda} = \bar{X}$ paraméterű Poisson-eloszlást a nézett sorozatok számának hisztogramjával.

```
sorozat=read.table("clipboard", header = FALSE, sep = "")  
  
curve(exp(-length(sorozat$V1)*x)*x^sum(sorozat$V1), from=0.1, to=5,  
lwd="3",  
main="Sorozatok száma", xlab="lambda", ylab="likelihood", col="blue")
```

Poisson-eloszlás paraméterének becslése



A sorozatok számának likelihood-függvénye, egy konstans szorzótól eltekintve:


$$\frac{\lambda^{\sum_{j=1}^n X_j} e^{-\lambda n}}{\prod_{j=1}^n X_j!}$$

$$n = 87, \sum_{j=1}^n X_j = 237, \text{ és } \bar{X} = 2,68$$

Poisson-eloszlás paraméterének becslése

```
pk=c(18,12,18,15,9,10,2,0,0,0,3, 1)/87
names(pk)<-c("0","1", "2", "3", "4", "5", "6","7","8", "9", "10", "11")
barplot(pk, col="#79a7f2", xlab="Megfigyelt értékek",
ylab="Relatív gyakoriságok",main="Sorozatok számának hisztogramja",
space=0, ylim=c(0, 0.3))
x=c(0,1,2,3,4,5,6,7,8, 9, 10, 11)
y=dpois(x, lambda=2.68)
x<-x+0.5
lines(y~ x, lwd="5", col="red", type="b")
legend("topright", c("megfigyelések", "Poisson(2,68)"), col=c("#79a7f2",
"red"), lwd="3")
```

Poisson-eloszlás paraméterének becslése



A sorozatok számának hisztogramja és Poisson-eloszlás $\hat{\lambda} = \bar{X} = 2,68$ becült paraméterrel

$$n = 87, \sum_{j=1}^n X_j = 237, \text{ és } \bar{X} = 2,68$$

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 $(\Omega, \mathcal{A}, \mathcal{P})$ 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

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

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

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:

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

A likelihood-függvényben csak n és a $\sum_{j=1}^n X_j$ összeg szerepel a paraméterrel együtt.


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

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 $s_n = 10,5$.

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

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

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

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

ML-becslés: normális eloszlás

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

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

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

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

A likelihood-függvényben csak a $\sum_{j=1}^n X_j^2$ **négyzetösszeg** és a $\sum_{j=1}^n X_j$ **összeg** szerepel a mintából a paraméterrel együtt:

$$\sum_{j=1}^n (X_j - m)^2 = \sum_{j=1}^n X_j^2 - 2m \sum_{j=1}^n X_j + m^2.$$

Elégséges statisztika

Definíció

Legyen X_1, \dots, X_n független minta ϑ paraméterű eloszlásból. A T statisztika elég-séges, ha a likelihood-függvény felírható a következő alakban megfelelő h és g függvényekkel:

$$L_{n,\vartheta}(X_1, \dots, X_n) = h(X_1, \dots, X_n) \cdot g_{\vartheta}(T(X_1, \dots, X_n)).$$

Elégséges statisztika

Definíció

Legyen X_1, \dots, X_n független minta ϑ paraméterű eloszlásból. A T statisztika elég-séges, ha a likelihood-függvény felírható a következő alakban megfelelő h és g függvényekkel:

$$L_{n,\vartheta}(X_1, \dots, X_n) = h(X_1, \dots, X_n) \cdot g_{\vartheta}(T(X_1, \dots, X_n)).$$

- Poisson-eloszlás esetén az összeg és az átlag is elég-séges statisztika.
- Normális eloszlásnál elég-séges statisztika: (\bar{X}, s_n) , vagy $(\sum_{j=1}^n X_j^2, \sum_{j=1}^n X_j)$.
- Az elég-séges statisztika nem egyértelmű.
- Ha létezik maximumlikelihood-becslés, T pedig elég-séges statisztika, akkor az ML-becslés felírható $u(T(X_1, \dots, X_n))$ alakban valamely u függvényre. Azaz, ahogy a példákban is láttuk, az elég-séges statisztikából kifejezhető a maximumlikelihood-becslés.

Hatásos becslés az elégséges statisztika segítségével

A következő tétel alapján egy

- torzítatlan becslésből kiindulva
- az elégséges statisztika függvényeként, arra feltételes várható értéket véve.
- egy hatásosabb, vagyis kisebb szórású, szintén torzítatlan becslés is készíthető.

Például Poisson-eloszlás esetén, ha a λ paramétert szeretnénk becsülni:

- $\mathbb{E}_\lambda(X_1) = \lambda$, ezért X_1 torzítatlan becslése λ -nak;
- $\sum_{j=1}^n X_j$ elégséges statisztika

Hatásos becslés az elégséges statisztika segítségével

A következő tétel alapján egy

- torzítatlan becslésből kiindulva
- az elégséges statisztika függvényeként, arra feltételes várható értéket véve.
- egy hatásosabb, vagyis kisebb szórású, szintén torzítatlan becslés is készíthető.

Például Poisson-eloszlás esetén, ha a λ paramétert szeretnénk becsülni:

- $\mathbb{E}_\lambda(X_1) = \lambda$, ezért X_1 torzítatlan becslése λ -nak;
- $\sum_{j=1}^n X_j$ elégséges statisztika
- tekintsük az alábbi feltételes várható értéket (ha az összeget tudjuk, mennyi lehetett X_1):

$$\mathbb{E}(X_1 | X_1 + \dots + X_n) = \bar{X}$$

- továbbra is torzítatlan becslést kaptunk, de a szórás lényegesen kisebb lett:

$$\mathbb{E}_\lambda(\bar{X}) = \mathbb{E}_\lambda(X_1) = \lambda; \quad D_\lambda(\bar{X}) = \frac{D_\lambda(X_1)}{\sqrt{n}} < D_\lambda(X_1).$$

Rao–Blackwell-tétel

Tétel (Rao–Blackwell)

Tegyük fel, hogy a T statisztika torzítatlan becslés a ϑ paraméterre, valamint S elégséges statisztika ϑ -ra. Ekkor megadható olyan T^ becslés, melyre*

- $T^* = h(S)$ megfelelő h függvénnyel;
- T^* torzítatlan ϑ -ra: $\mathbb{E}_{\vartheta}(T^*) = \vartheta$ minden $\vartheta \in \Theta$ -ra;
- T^* hatásosabb, mint T : $D_{\vartheta}(T^*) \leq D_{\vartheta}(T)$ minden $\vartheta \in \Theta$ -ra.

Ha az S statisztika teljes is (azaz minden olyan f függvény, melyre $\mathbb{E}_{\vartheta}(f(S)) = 0$ minden ϑ -ra, „majdnem mindenütt” nulla), akkor T^ hatásos, azaz minden torzítatlan becslésnél hatásosabb.*

A megoldás az $\mathbb{E}(T|S)$ feltételes várható érték lesz. Például Poisson-eloszlásnál $\mathbb{E}(X_1 | \sum_{j=1}^n X_j) = \bar{X}$ hatásos.

Állítás

Poisson-eloszlásnál normális eloszlásoknál (m -re) a mintaelemek összege teljes elégséges statisztika, a mintaátlag pedig hatásos becslése a paraméternek.

Fisher-információ

Egy mintaelem **Fisher-információja**:

$$I_1(\vartheta) = \mathbb{E}_{\vartheta} \left(\left(\frac{\partial}{\partial \vartheta} \log f_{\vartheta}(X_1) \right)^2 \right),$$

ahol f_{ϑ} a likelihoodfüggvény \mathbb{P}_{ϑ} mellett.

Fisher-információ

Egy mintaelem **Fisher-információja**:

$$I_1(\vartheta) = \mathbb{E}_{\vartheta} \left(\left(\frac{\partial}{\partial \vartheta} \log f_{\vartheta}(X_1) \right)^2 \right),$$

ahol f_{ϑ} a likelihoodfüggvény \mathbb{P}_{ϑ} mellett.

- Megfelelő (regularitási) feltételek mellett a független azonos eloszlású, n elemű minta Fisher-információja: $I_n(\vartheta) = n \cdot I_1(\vartheta)$.
- Ha T elégséges statisztika, akkor $T(X_1, \dots, X_n)$ Fisher-információja ugyanaz, mint (X_1, \dots, X_n) Fisher-információja (például Poisson-eloszlásnál az átlag Fisher-információja ugyanaz, mint a teljes mintáé).
- **Cramér–Rao-egyenlőtlenség**: megfelelő (regularitási) feltételek mellett, ha T torzítatlan becslés ϑ -ra, akkor

$$D^2(T(X)) \geq \frac{1}{I_n(\vartheta)} = \frac{1}{nI_1(\vartheta)}.$$

(Ebben az értelemben feleakkora szóráshoz négyszer annyi mintaelem kell.)

Fisher-információ

Egy mintaelem **Fisher-információja**:

$$I_1(\vartheta) = \mathbb{E}_{\vartheta} \left(\left(\frac{\partial}{\partial \vartheta} \log f_{\vartheta}(X_1) \right)^2 \right),$$

ahol f_{ϑ} a likelihoodfüggvény \mathbb{P}_{ϑ} mellett.

Néhány nevezetes eloszlás Fisher-információja egy mintaelemből:

- binomiális eloszlás n renddel és p paraméterrel:

$$\frac{n}{p(1-p)}.$$

- Poisson-eloszlás λ paraméterrel: $1/\lambda$
- normális eloszlás, ha $\vartheta = (m, \sigma)$:

$$\begin{pmatrix} \frac{1}{\sigma^2} & 0 \\ 0 & \frac{2}{\sigma^2} \end{pmatrix}.$$

Fisher-információ: Poisson-eloszlás

Egy mintaelem **Fisher-információja** (az f_λ likelihood-függvény most a valószínűség):

$$\begin{aligned} I_1(\lambda) &= \mathbb{E}_\lambda \left(\left(\frac{\partial}{\partial \lambda} \log f_\lambda(X_1) \right)^2 \right) = \mathbb{E}_\lambda \left(\left(\frac{\partial}{\partial \lambda} \log \left(\frac{\lambda^{X_1}}{X_1!} e^{-\lambda} \right) \right)^2 \right) = \\ &= \mathbb{E}_\lambda \left(\left(\frac{\partial}{\partial \lambda} \left(X_1 \log \lambda - \log X_1! - \lambda \right) \right)^2 \right) = \mathbb{E}_\lambda \left(\left(\frac{X_1}{\lambda} - 1 \right)^2 \right) = \\ &= \mathbb{E}_\lambda \left(\frac{X_1^2}{\lambda} - 2 \frac{X_1}{\lambda} + 1 \right) = \frac{\lambda + \lambda^2}{\lambda} - 2 + 1 = \frac{1}{\lambda}. \end{aligned}$$

Felhasználtuk, hogy Poisson-eloszlásnál $\mathbb{E}_\lambda(X_1) = D_\lambda(X_1) = \lambda$, így

$$\mathbb{E}_\lambda(X_1^2) = D_\lambda^2(X_1) + \mathbb{E}_\lambda^2(X_1) = \lambda + \lambda^2.$$

Következmény a **Cramér–Rao-egyenlőtlenség** alapján: ha T torzítatlan becslése λ -nak n elemű független mintából, akkor

$$D^2(T(X_1, \dots, X_n)) \geq \frac{1}{n\lambda}.$$

Konfidenciaintervallum az ML-bebecslés alapján

Gyakran az ismeretlen paraméterre egyetlen bebecslés helyett konfidenciaintervallumot adhatunk meg, amire például az igaz, hogy

$$\mathbb{P}_\vartheta(T_1 \leq \vartheta \leq T_2) \geq 0,95 \quad (\vartheta \in \Theta)$$

. Ez egy olyan véletlen intervallum, ami 95%-os megbízhatóságú, azaz legalább ennyi valószínűséggel tartalmazza a bebecsülni kívánt paramétert.

Konfidenciaintervallum az ML-becslés alapján

Gyakran az ismeretlen paraméterre egyetlen becslés helyett konfidenciaintervallumot adhatunk meg, amire például az igaz, hogy

$$\mathbb{P}_\vartheta(T_1 \leq \vartheta \leq T_2) \geq 0,95 \quad (\vartheta \in \Theta)$$

. Ez egy olyan véletlen intervallum, ami 95%-os megbízhatóságú, azaz legalább ennyi valószínűséggel tartalmazza a becsülni kívánt paramétert.

Állítás

Ha likelihoodfüggvény teljesít bizonyos regularitási feltételeket, akkor a ϑ paraméternek az X_1, X_2, \dots, X_n mintából számolt $\hat{\vartheta}_n$ maximumlikelihood-becslése

- létezik;
- aszimptotikusan torzítatlan: $\lim_{n \rightarrow \infty} \mathbb{E}_\vartheta(\hat{\vartheta}_n) = \vartheta$ minden $\vartheta \in \Theta$ -ra;
- aszimptotikusan hatásos: $\lim_{n \rightarrow \infty} \sqrt{nl_1(\vartheta)} D_\vartheta(\hat{\vartheta}_n) = 1$ minden $\vartheta \in \Theta$ -ra;
- aszimptotikusan normális eloszlású: $\sqrt{nl_1(\vartheta)}(\hat{\vartheta}_n - \vartheta)$ eloszlásban tart a standard normális eloszláshoz minden $\vartheta \in \Theta$ -ra $n \rightarrow \infty$ esetén.

Itt $l_1(\vartheta)$ az egyelemű mintából számolt Fisher-információt jelöli.

Konfidenciaintervallum az ML-becslés alapján

Ez alapján **aszimptotikus konfidenciaintervallum**, ami $n \rightarrow \infty$ esetén $1 - \alpha$ -hoz tartó valószínűséggel tartalmazza ϑ -t:

$$\left(\hat{\vartheta}_n - \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{1}{\sqrt{\hat{I}_n(\vartheta)}}; \hat{\vartheta}_n + \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{1}{\sqrt{\hat{I}_n(\vartheta)}} \right),$$

ahol $\hat{I}_n(\vartheta) = n \cdot I_1(\hat{\vartheta}_n)$, vagyis a Fisher-információ kifejezésébe a maximumlikelihood-becslést írjuk be.

Másképpen felírva:

$$\lim_{n \rightarrow \infty} \mathbb{P}_{\vartheta} \left(\hat{\vartheta}_n - \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{1}{\sqrt{\hat{I}_n(\vartheta)}} \leq \vartheta \leq \hat{\vartheta}_n + \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \cdot \frac{1}{\sqrt{\hat{I}_n(\vartheta)}} \right) = 1 - \alpha.$$

Itt is vegyük észre, hogy ϑ ismeretlen, de rögzített paraméter, és az intervallum alsó és felső végpontjai véletlenek, az eloszlásuk is ϑ -tól függ (ezt jelöli a ϑ az alsó indexben).

Bayes-becslés: bevezetés

Eddig a statisztikai elemzésekben a **frekventista hozzáállást** követtük. A $\vartheta \in \Theta$ paraméter számunkra ismeretlen, és csak azt tesszük fel róla, hogy egy ismert Θ halmaznak, a paraméterternek az eleme. A Θ paraméterter rögzített halmaz saját struktúra nélkül, a tulajdonságoknak (például konzisztencia, torzítatlanság) minden $\vartheta \in \Theta$ -ra teljesülniük kell. Ezért előzetes információt nem tudunk jól felhasználni.

Bayes-becslés: bevezetés

Eddig a statisztikai elemzésekben a **frekventista hozzáállást** követtük. A $\vartheta \in \Theta$ paraméter számunkra ismeretlen, és csak azt tesszük fel róla, hogy egy ismert Θ halmaznak, a paramétertérnek az eleme. A Θ paramétertér rögzített halmaz saját struktúra nélkül, a tulajdonságoknak (például konzisztencia, torzítatlanság) minden $\vartheta \in \Theta$ -ra teljesülniük kell. Ezért előzetes információt nem tudunk jól felhasználni.

Ennek a módszernek egy hátránya például:

- egy gyógyszert n -szer kipróbálva 0 esetben lépett fel mellékhatás;
- legyen p a mellékhatás kialakulásának valószínűsége;
- ezt a relatív gyakorisággal becsülhetjük: $\hat{p} = 0$. Ez torzítatlan, konzisztens becslés, a frekventista hozzáállás követelményeinek megfelel.
- Ugyanakkor, ha $n = 20$ kipróbálásból nem alakult ki mellékhatás, az egész más, mintha $n = 2000$ kipróbálásnál sem talákoztunk ezzel. Ezt a becslés nem tükrözi.

Bayes-i hozzáállás: a paramétert magát is valószínűségi változónak tekintjük, ebbe beépítve valamilyen előzetes információt.

A priori és a posteriori eloszlás: példa

Példa. Egy biztosító háromféle ügyfelet különböztet meg:

- az óvatos, átlagos és merész sofőröket;
- az, hogy egy ügyfél hány balesetet okoz egy év alatt, Poisson-eloszlású, 0, 1, 0, 2 és 0, 3 paraméterekkel az egyes csoportoknál
- egy új ügyfél mindhárom csoportba azonos, $1/3$ valószínűséggel tartozik
- az éveket függetlennek tekintjük
- Péter az utóbbi tíz évben egyáltalán nem okozott balesetet
- adjunk becslést a Péter által egy év alatt okozott balesetek számát leíró Poisson-eloszlás λ paraméterére

A priori és a posteriori eloszlás: példa

Itt a λ ismeretlen paraméter valószínűségi változónak tekinthető, aminek az eloszlásáról az előzetes feltételezésünk:

$$\mathbb{P}(\lambda = 0, 1) = \mathbb{P}(\lambda = 0, 2) = \mathbb{P}(\lambda = 0, 3) = \frac{1}{3}.$$

A paraméter eloszlásáról alkotott előzetes, a minta megismerése előtt feltételezett eloszlás az **a priori eloszlás**. Ez tükrözi a paraméterre vonatkozó, a megfigyelésnél korábbi információkat.

Legyen A az az esemény, hogy Péter tíz év alatt nem okozott balesetet. Ennek valószínűsége, ha s a rá jellemző eloszlás igazi paramétere:

$$\mathbb{P}(A|\lambda = s) = (e^{-s})^{10} = e^{-10s},$$

a Poisson-eloszlás definícióját $k = 0$ -val használva.

A priori és a posteriori eloszlás: példa

Hogyan módosul az egyes lehetséges értékek valószínűsége, ha felhasználjuk, hogy A bekövetkezett?

A Bayes-tétel alapján

$$\mathbb{P}(\lambda = 0, 1|A) = \frac{\mathbb{P}(A|\lambda = 0, 1)\mathbb{P}(\lambda = 0, 1)}{\sum_{j=1}^3 \mathbb{P}(A|\lambda = j \cdot 0, 1)\mathbb{P}(\lambda = j \cdot 0, 1)}$$

A priori és a posteriori eloszlás: példa

Hogyan módosul az egyes lehetséges értékek valószínűsége, ha felhasználjuk, hogy A bekövetkezett?

A Bayes-tétel alapján

$$\mathbb{P}(\lambda = 0, 1|A) = \frac{\mathbb{P}(A|\lambda = 0, 1)\mathbb{P}(\lambda = 0, 1)}{\sum_{j=1}^3 \mathbb{P}(A|\lambda = j \cdot 0, 1)\mathbb{P}(\lambda = j \cdot 0, 1)}$$

$$\mathbb{P}(\lambda = 0, 1|A) = \frac{e^{-10 \cdot 0,1} \cdot \frac{1}{3}}{(e^{-10 \cdot 0,1} + e^{-10 \cdot 0,2} + e^{-10 \cdot 0,3}) \cdot \frac{1}{3}} = \frac{e^{-1}}{e^{-1} + e^{-2} + e^{-3}} = 66,5\%.$$

A priori és a posteriori eloszlás: példa

Hogyan módosul az egyes lehetséges értékek valószínűsége, ha felhasználjuk, hogy A bekövetkezett?

A Bayes-tétel alapján

$$\mathbb{P}(\lambda = 0, 1|A) = \frac{\mathbb{P}(A|\lambda = 0, 1)\mathbb{P}(\lambda = 0, 1)}{\sum_{j=1}^3 \mathbb{P}(A|\lambda = j \cdot 0, 1)\mathbb{P}(\lambda = j \cdot 0, 1)}$$

$$\mathbb{P}(\lambda = 0, 1|A) = \frac{e^{-10 \cdot 0,1} \cdot \frac{1}{3}}{(e^{-10 \cdot 0,1} + e^{-10 \cdot 0,2} + e^{-10 \cdot 0,3}) \cdot \frac{1}{3}} = \frac{e^{-1}}{e^{-1} + e^{-2} + e^{-3}} = 66,5\%.$$

Hasonlóképpen:

$$\mathbb{P}(\lambda = 0, 2|A) = \frac{e^{-2}}{e^{-1} + e^{-2} + e^{-3}} = 24,5\%$$

$$\mathbb{P}(\lambda = 0, 3|A) = \frac{e^{-3}}{e^{-1} + e^{-2} + e^{-3}} = 9\%.$$

A feltételes valószínűségek tehát eltérnek az a priori eloszlástól, ott mindegyik 1/3 volt, most az óvatos a legvalószínűbb.

A priori és a posteriori eloszlás: példa

A priori eloszlás: a paraméterre vonatkozó előzetes információt tükrözi, a mintát nem használja. A példában:

$$\mathbb{P}(\lambda = 0, 1) = \mathbb{P}(\lambda = 0, 2) = \mathbb{P}(\lambda = 0, 3) = \frac{1}{3}.$$

A posteriori eloszlás: a paraméter feltételes eloszlása a mintára, megfigyelésekre nézve. A példában:

$$\mathbb{P}(\lambda = 0, 1|A) = 66,5\%; \quad \mathbb{P}(\lambda = 0, 2|A) = 24,5\%; \quad \mathbb{P}(\lambda = 0, 3|A) = 9\%.$$

Ez még nem ad meg egyetlen számot becslésként, ebben a példában ilyen nem is fogunk meghatározni.

Bayes-becslés

Példa. Tegyük fel, hogy egy biztosító minden ügyfeléről azt feltételezi, hogy az általa egy év alatt okozott balesetek száma Poisson-eloszlású, paramétere pedig az ügyfélre jellemző λ , mely egy ügyfelet tekintve egyenletes eloszlású a $[0, 1]$ intervallumon. Adjunk becslést a Péterre jellemző λ paraméterre, ha Péter az utóbbi tíz évben egyetlen balesetet sem okozott.

Bayes-becslés

Példa. Tegyük fel, hogy egy biztosító minden ügyfeléről azt feltételezi, hogy az általa egy év alatt okozott balesetek száma Poisson-eloszlású, paramétere pedig az ügyfélre jellemző λ , mely egy ügyfelet tekintve egyenletes eloszlású a $[0, 1]$ intervallumon. Adjunk becslést a Péterre jellemző λ paraméterre, ha Péter az utóbbi tíz évben egyetlen balesetet sem okozott.

Az alábbi egyenlet ugyanúgy érvényes, mint eddig, minden $s \in [0, 1]$ -re:

$$\mathbb{P}(A|\lambda = s) = (e^{-s})^{10} = e^{-10s}.$$

A Bayes-tétel (folytonos változata) azonban most ezt adja:

$$p^*(s|A) = \frac{\mathbb{P}(A|\lambda = s)p(s)}{\int_{-\infty}^{\infty} \mathbb{P}(A|\lambda = t)p(t)dt},$$


ahol p a paraméter a priori sűrűségfüggvénye. A példában $p(t) = \mathbb{I}(0 \leq t \leq 1)$, hiszen azt tettük fel előzetesen, hogy t egyenletes eloszlású a $[0, 1]$ intervallumon.

Bayes-becslés

Behelyettesítve megkapjuk az a posteriori eloszlás sűrűségfüggvényét:

$$p^*(s|A) = \frac{\mathbb{P}(A|\lambda = s)p(s)}{\int_{-\infty}^{\infty} \mathbb{P}(A|\lambda = t)p(t)dt} = \frac{e^{-10s}\mathbb{I}(0 \leq s \leq 1)}{\int_0^1 e^{-10t} dt} = \frac{e^{-10s}\mathbb{I}(0 \leq s \leq 1)}{\frac{1}{10}(1 - e^{-10})}$$

Vagyis a megfigyelések alapján s -t olyan eloszlásúnak gondolhatjuk, aminek ez a fenti függvény a sűrűségfüggvénye.



Házi feladat március 21., hétfő, 10:30-ig

Legyenek X_1, X_2, \dots, X_n független valószínűségi változók, a sűrűségfüggvénye mind-egyiknek

$$f(x) = \frac{\lambda^3 x^2}{2} e^{-\lambda x} \mathbb{I}(x > 0),$$

ahol $\mathbb{I}()$ értéke 1, ha igaz a benne szereplő feltétel, 0 különben.

Adjunk meg minél kevesebb, legfeljebb 3 elemből álló elégséges statisztikát (X_1, X_2, \dots maga mindig elégséges statisztika, de ez n elemből áll, nem jó most).