

Leíró és matematikai statisztika

Matematika alapszak, matematikai elemző szakirány

Zempléni András

Valószínűségelméleti és Statisztika Tanszék
Matematikai Intézet
Természettudományi Kar
Eötvös Loránd Tudományegyetem

Honlap: zempleni.elte.hu

E-mail: andras.zempleni@ttk.elte.hu

Szoba: D 3-310

4. előadás

Az elégséges statisztika tulajdonságai

- Az elégséges statisztika nem egyértelmű: szigorúan monoton függvénybe behelyettesíthetjük
- Sőt: ha hozzáveszünk újabb statisztikákat, akkor is elégséges marad.
- Ezért a célunk minél egyszerűbb elégséges statisztika keresése.
- A maximum likelihood becslés az elégséges statisztika függvénye.

Definíció. [hatásosság] Egy T torzítatlan becslés hatásos, ha minden más T^* torzítatlan becslésre $D_{\vartheta}^2 T(\mathbf{X}) \leq D_{\vartheta}^2 T^*(\mathbf{X})$ minden $\vartheta \in \Theta$ paraméterre

- Megjegyzés: a hatásos becslés nem mindig létezik, de ha van ilyen, akkor egyértelmű.
- Az általános (nem feltétlenül torzítatlan) esetre $E_{\vartheta}(T(\mathbf{X}) - \vartheta)^2$ minimalitása definiálja a hatásosságot

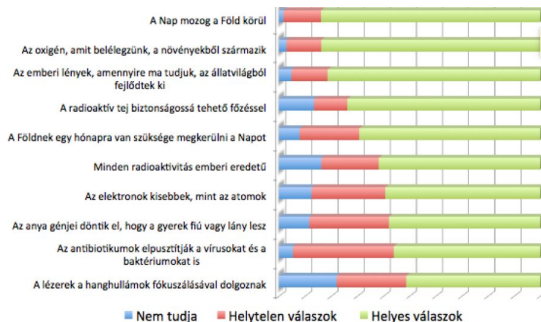
- Rao-Blackwell tétel: Ha T torzítatlan becslés a ϑ paraméterre és S elégséges statisztika ϑ -ra, akkor megadható olyan becslés, mely
 - S függvénye
 - torzítatlan ϑ -ra
 - kisebb szórású, mint T
- $E(T|S)$ lesz a megoldás.

E23.) Adjunk meg "jó" becslést az $\{1, 2, \dots, a\}$ számokon egyenletes eloszlás paraméterére a Rao-Blackwell tétel segítségével! **E24.)**

Legyen X_1, \dots, X_n i.i.d. abszolút folytonos valószínűségi változók sorozata.

- Adjuk meg az i -edik rendezett mintaelem, azaz X_i^* eloszlás- és sűrűségfüggvényét ($1 \leq i \leq n$)!
- Milyen eloszlású X_i^* , amennyiben a mintaelemek $(0; 1)$ -en egyenletesek? Határozzuk meg az EX_i^* mennyiséget!

Egy érdekes felmérés:



És az értelmezése:

- "nálunk 800 ezer ember gondolja úgy, hogy a Nap kering a Föld körül" (minden portál)
- "A megkérdezettek mintegy 40 százaléka sem azt nem tudta, hogy az atomok vagy az elektronok kisebbek-e, sem azt, hogy az antibiotikumokat milyen kórokozók ellen érdemes bevetni" (qubit)

E25.) Egy véletlenszám-generátorral 20 véletlen számot állítunk elő egy ismeretlen (a, b) intervallumból. A kapott véletlen számok sorrendbe téve és (egyszerűség kedvéért) egésyre kerekítve:

5 11 12 13 13 14 17 19 21 22
23 24 25 27 31 31 32 35 36 38

- a.) Adjuk meg a mintateret és a paraméterteret!
- b.) Határozzuk meg az ismeretlen paraméterek maximum likelihood becslését!
- c.) Határozzuk meg a paraméterek momentum-becslését! Értékeljük a kapottakat!
- d.) Torzítatlanok az ML-becslések? Ha nem, akkor tegyük őket torzítatlanná!
- e.) Konzisztensek az ML-becslések?

Sűrűségfüggvény becslése – magfüggvényes módszer (Parzen-Rosenblatt becslés)

$$f_n(x) = \frac{1}{n \cdot h_n} \sum_{i=1}^n K\left(\frac{x - X_i}{h_n}\right), \text{ ahol}$$

- $K : \mathbb{R} \rightarrow \mathbb{R}$ páros sűrűségfüggvény, neve: magfüggvény
- h_n sáv szélesség, pl. $h_n = n^c$, ahol $-1 < c < 0$ valós szám
- Ekkor korlátos K -ra f_n konzisztens becslés f folyt.-i pontjaiban

A leggyakoribb magfüggvények:

Magfüggvény neve	$K(x)$
Gauss	$\frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$
téglalap (rectangular)	$\frac{1}{2} I(x \leq 1)$
háromszög (triangular)	$(1 - x) \cdot I(x \leq 1)$
Bartlett–Epanechnikov	$\frac{3}{4} (1 - x^2) \cdot I(x \leq 1)$
cosinus	$\frac{\pi}{4} \cos\left(\frac{\pi}{2} x\right) \cdot I(x \leq 1)$

Mi az "optimális" h_n ? \rightsquigarrow amivel $f_n(x)$ "legjobban" közelíti a valódi sfv-t.

Eloszlásfüggvény/sűrűségfüggvény becslése: példák

Eloszlásfüggvény (F) becslése tapasztalati eloszlásfüggvénnyel (F_n): nemcsak torzítatlan és konzisztens, hanem egyenletesen is konvergál:

$$\sup_{x \in \mathbb{R}} |F(x) - F_n(x)| \rightarrow 0 \quad n \rightarrow \infty$$


(Glivenko tétele)

E26.)

- a.) Legyen a rendezett mintánk 1,2,5,6,12. Számoljuk ki a sűrűségfüggvény becslését, ha $h = 0,5$ és a téglalap-magfüggvényt alkalmazzuk!
- b.) Mennyiben változik a becslés, ha a háromszög-magfüggvényt választjuk?
- c.) Mennyi az R által alkalmazott default sáv szélesség?

Egy "érdekes" ábra

PLANNED PARENTHOOD FEDERATION OF AMERICA:
ABORTIONS UP — LIFE-SAVING PROCEDURES DOWN



Furcsa COVID adatok

Horvátország	544 → 443	31%	▲
Németország	11294 → 8114	8%	▲
Dánia	720 → 524	9%	▲
Spanyolország	36826 → -4464	-148%	▼

A Fisher-információ, becslések hatásossága

- A minta (elméleti) információjája:

$$I_n(\vartheta) = E_{\vartheta} (\partial_{\vartheta} \ell(\vartheta, \mathbf{X}))^2$$

- Tulajdonságok:

- A reguláris esetben $I_n(\vartheta) = nI_1(\vartheta)$.
- Ha másodrendben is reguláris a függvény, akkor

$$I_n(\vartheta) = -E_{\vartheta} (\partial_{\vartheta}^2 \ell(\vartheta, \mathbf{X}))$$

Definíció [hatásosság] Egy T torzítatlan becslés hatásos, ha minden más T^* torzítatlan becslésre $D_{\vartheta}^2 T(\mathbf{X}) \leq D_{\vartheta}^2 T^*(\mathbf{X})$ minden $\vartheta \in \Theta$ paraméterre

- Megjegyzés: a hatásos becslés nem mindig létezik, de ha van ilyen, akkor egyértelmű.
- Az általános (nem feltétlenül torzítatlan) esetre $E(T(\mathbf{X}) - \vartheta)^2$ minimalitása definiálja a hatásosságot

- hatásos becslés keresése az információs határ segítségével
Cramér-Rao egyenlőtlenség: A reguláris esetben

$$D_{\vartheta}^2(T(\mathbf{X})) \geq \underbrace{\frac{(g'(\vartheta))^2}{I_n(\vartheta)}}_{\text{információs határ}}$$

Ha egy $g(\vartheta)$ -ra nézve torzítatlan T statisztika esetén egyenlőség teljesül, akkor az a statisztika hatásos becslése $g(\vartheta)$ -nak.

- az ML-becslés eloszlásban egy olyan normális eloszláshoz tart, aminek a szórásnégyzete a Fisher-információ inverze
- intervallumbecslés az ML-becslésre
- kísérlettervezés
- Bayes-i statisztika – Jeffrey-féle apriori eloszlás számításához
- neurális hálók, machine learning
- számítógépes agykutatás

Az információk határ felfedezői/névadóí

Harald Cramér (1893 – 1985)



C. R. Rao (1920 –)



E27.) Legyen X_1, \dots, X_n i.i.d. $\text{Ind}(p)$ eloszlású.

- a.) Határozzuk meg a mintában lévő Fisher-információ értékét!
- b.) Mutassuk meg, hogy a relatív gyakoriság hatásos becslése a valószínűségnek!

E28.) Legyen X_1, \dots, X_n i.i.d. $\text{Exp}(\lambda)$ eloszlású.

- a.) Határozzuk meg a mintában lévő Fisher-információ értékét!
- b.) Mutassuk meg, hogy a mintaátlag hatásos becslése $\frac{1}{\lambda}$ -nak!

- Ha a likelihood függvény teljesít bizonyos regularitási feltételeket, akkor a maximum likelihood becslés $\hat{\vartheta}_n$
 - létezik
 - aszimptotikusan torzítatlan
 - aszimptotikusan hatásos:

$$\sqrt{nl_1(\vartheta)}D(\hat{\vartheta}_n) \rightarrow 1 \quad (n \rightarrow \infty)$$

- Az alábbi függvénye aszimptotikusan standard normális eloszlású:

$$\sqrt{nl_1(\vartheta)}(\hat{\vartheta}_n - \vartheta) \quad (n \rightarrow \infty)$$