

Statisztika alapok

1/12

A statisztika alapfeladata: $X \in \mathbb{R}$ valószínűségi változó
adott, de ismeretlen. X_1, X_2, X_3, \dots független és X -szel
azonos eloszlású.

Ezek egyetlen realizációja $X_1, X_2, \dots, X_n \leftarrow$ VÉGES hosszú
sorozat,
ezt megfigyeljük: MINTÁT VESZÜNK X -ből

[Azaz: rendelkezésünkre áll n db szám.]

Kérdés: Mi X eloszlása?

1. válasz: Nyilván nem lehet tudni.

Leggyakoribb eset: Egy hamis érmen a fej valószínűsége p :
ez adott, de nem ismerjük.

Feldobtuk $n=100$ -szor, és azt kaptuk, hogy

F I F I F F F I I . . . F F
60 db F, 40 db I

Mennyi p értéke?

Legelső természetes tipp: $\frac{60}{100} = 0.6$.

Igen ám, de

- (2/12)
- Lehet, hogy $p = 0.5$? Válasz: Hát persze, lehet.
 - Lehet, hogy $p = 0.01$? Válasz: Igen, az is lehet.
 - Na jó, de azt gondoljuk, hogy $p = 0.6$?

Válasz: Nem, nem gondoljuk.

Miért is lenne ilyen szép kerek szám?

Simán lehet, hogy $p = 0.601032$, csak hát $n = 100$ kísérletből ilyet lehetetlen kimérni.

- Azért mégis valószínűbb, hogy $p = 0.6$, mint hogy $p = 0.01$, nem?

Válasz: De, igen...?...

Második, kicsit értelmesebb állítás:

Nem tudjuk, hogy p mennyi, de nagy valószínűséggel
~~az~~ 0.5 és 0.7 között van.

[Nem fogom megmutatni, de igazából jelen esetben 95%]

Micsoda?!?! Hol itt a valószínűség?

Válasz: Sehol (̄) ugyanis

→ a p szám egy objektív létező
(bár nem ismerjük).

→ Mint ilyen, vagy 0,5 és 0,7 között van,
vagy sem.

→ Valószínűségről akkor lenne értelmes beszélni,
ha nekünk „kísérlet”-et végezhetnénk, ezek
egy részében $p \in [0,5; 0,7]$ lehetne
más részében meg nem.

De itt nincsenek kísérletek.

Terv a statisztika mikro-kurzusra:

- Megértjük, hogy milyen értelemben „legjobb tipp” a $p=0,6$
- Értelmessé tesszük a „95% valószínűséggel $p \in [0,5; 0,7]$ kijelentést.
- Ha az érme gyártója azt állítja, hogy igazából $p=0,4$,
eldöntjük, hogy higgyünk-e neki vagy sem.

Lényeg röviden: Ha valaki bizik abban, hogy $p \in [0,5; 0,7]$,

az bizik a szerencséjében, de

Nem abban bizik, hogy szerencséje lesz,

hanem abban, hogy szerencséje volt,

(amikor a kísérletet végezte).

Megj: másik véglet / legnehézebb eset:

Titkosított jelek érkeznek a világról - mindegyik egy szám. Forrásukról, jelentésükről fogalmunk sincs.

Megfigyeltünk 10-et, és az jött ki, hogy

-3	17	5	108	1210.3
1	10	100	-17	-40

Mi lehet X eloszlása?

Ez így végképp reménytelen:

- lehet, hogy $X \sim U_n[-100; 1300]$
- de az is lehet, hogy X diszkrét, és csak ezt a 10 értéket veheti fel.

Megj:2: Más lenne a helyzet, ha vehetnénk egy

$X_1, X_2, X_r \dots$ végtelen mintát.

Ebből 1 valósággal pontosan rekonstruálható lenne bármilyen eloszlás.

Kár, hogy a statisztikában minden minta véges n

Momentum-becslések

Legyen X val. változó, $m = EX$, $\sigma^2 = \text{Var } X = D^2 X$.

Mintát veszünk X -ből: x_1, x_2, \dots, x_n

Vajon mennyi lehet m és σ ?

Def: átlag: $\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n}$

Def:
terzitatlan becslése
a m várható értékek: $E(\text{becslés}) = \text{tényleges érték}$

Fő hírd: $E\bar{x} = m$, vagyis az átlag

Perste: értsd jól: Ha $X_1, X_2, \dots, X_n \sim X$ függetlenek

és $\bar{X} = \frac{X_1 + \dots + X_n}{n}$, akkor \bar{X} val. változó,

$$\text{és } E\bar{X} = \frac{1}{n} [EX_1 + EX_2 + \dots + EX_n] = \frac{1}{n} \underbrace{[m + m + \dots + m]}_{n \text{ db}} = m.$$

Perste, miután a kísérletek elvégestük és kijön mondjuk, hogy $\bar{x} = 0.6$, ez már csak egy szám,

$E\bar{x} = E0.6 = 0.6$ nem til értelmes, és főleg általában $\neq m$.

6/12

Gonosz megjegyzés:

Ezért kár volt ennyit számolni.

Legyen a becslésünk simán csak X_1 : az dsőt felírom, a többit meg se nézem.

Ez is torzítatlan becslése m -nek, hiszen $E X_1 = m$.

Jó hír 2: Ha $n \rightarrow \infty$, akkor

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} \longrightarrow m \quad \text{1 valószínűséggel,}$$

$\bar{X}(n)$ az a nagy számok törvénye.

Avagy: \bar{X} Def: konzisztens becslés m -re:
becslés $\xrightarrow{n \rightarrow \infty}$ tényleges érték

Ebben az értelemben, ha n nagy, akkor \bar{X} jobb becslés, mint X_1 .

Játszunk el most ugyanezt σ -ra, hiszen

$$\sigma^2 = \text{Var } X = E((X-m)^2) \text{ maga is egy várható érték:}$$

[K:] Miért ne legyen a becslése

$$\frac{(X_1-m)^2 + (X_2-m)^2 + \dots + (X_n-m)^2}{n} = \frac{1}{n} \sum_{i=1}^n (X_i-m)^2 \quad ?$$

Válasz: Ez rendbe lenne, ha m -et ismerünk...

17/12

[Megj: És fontos: ha m -et ismerjük, akkor
 $\frac{1}{n} \sum_{i=1}^n (x_i - m)^2$ torzítatlan és konzisztens
becslése σ^2 -nek.]

De általában m -et nem ismerjük.

Ötlet: jobk híján írjuk be m helyére a becslést, \bar{x} -ot!

Def: Az x_1, x_2, \dots, x_n mintából számolt tapasztalati

szórásnégyzet $S_n^2 := \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$.

Tétel (könnyű számolás):

$$S_n^2 = \underbrace{\left[\frac{1}{n} \sum_{i=1}^n x_i^2 \right]}_{\text{négyzetek}} - \underbrace{\bar{x}^2}_{\text{átlag négyzete}}$$

Köv: S_n^2 konzisztens becslése σ^2 -nek.

Biz: $\frac{1}{n} \sum_{i=1}^n x_i^2 \xrightarrow[\text{törvbnyep}]{\text{Nagy számok}} E(x^2)$; $\bar{x} \xrightarrow[\text{N. S.T.}]{} m$

$\Rightarrow S_n^2 \rightarrow E(x^2) - m^2 = \sigma^2 \quad \square$

~~Köv: S_n~~

Def: $S_n = \sqrt{S_n^2}$ a tapasztalati szórási.

Köv: S_n konzisztens becslése σ -nak.

Biz: Hat persze: $S_n^2 \rightarrow \sigma^2 \iff S_n = \sqrt{S_n^2} \rightarrow \sqrt{\sigma^2} = \sigma$]

Kérdés: No, és S_n^2 terztatlan becslése σ^2 -nek?

Válasz: Közép-szórnyú standardis, de ERDEMES

Végiggondni:

$$E S_n^2 = E \frac{1}{n} \sum_{i=1}^n X_i^2 - E \left[\left(\frac{1}{n} \sum_{i=1}^n X_i \right)^2 \right]$$

|| könnyű ezt nézzük meg jobban

$$\frac{1}{n} \sum_{i=1}^n E(X_i^2) = \frac{1}{n} n E(X^2) = E(X^2)$$

$$\text{2. tag: } E \left[\left(\frac{1}{n} \sum_{i=1}^n X_i \right)^2 \right] = E \left[\frac{1}{n} \left(\sum_{i=1}^n X_i \right) \frac{1}{n} \left(\sum_{j=1}^n X_j \right) \right] =$$

$$= \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n E(X_i X_j) \leftarrow n^2 \text{ db tag}$$

Ebből • ha $i=j$, akkor $X_j = X_i \Rightarrow E(X_i X_j) = E(X_i^2) = E(X^2)$,
ilyen tag van n darab

• ha $i \neq j$, akkor X_i és X_j független $\Rightarrow E(X_i X_j) = E X_i \cdot E X_j =$
 $= (E X)^2$; ilyen tag van $(n^2 - n)$ darab

Vagyis

$$2. \text{ tag} \stackrel{\text{felvt.}}{=} \frac{1}{n^2} \left[n E(X^2) + \overbrace{(n^2 - n)}^{n(n-1)} (EX)^2 \right]$$

$$= \frac{1}{n} E(X^2) - \frac{n-1}{n} (EX)^2$$

Egybeírva:

$$E S_n^2 = \underbrace{E(X^2) - \frac{1}{n} E(X^2)}_{\underbrace{\left(1 - \frac{1}{n}\right) E(X^2)}_{\frac{n-1}{n}}} + \frac{n-1}{n} (EX)^2 = \frac{n-1}{n} \left[E(X^2) - (EX)^2 \right]$$

$$= \frac{n-1}{n} \text{Var} X = \frac{n-1}{n} \sigma^2$$

Tétel: $E S_n^2 = \frac{n-1}{n} \sigma^2$.

Vagyis S_n^2 NEM torzítatlan becslése σ^2 -nek, csak

Def: aszimptotikusan torzítatlan:

$E(\text{becslés}) \xrightarrow{n \rightarrow \infty} \text{tényleges érték}$

Ezért hát

Def: Az x_1, x_2, \dots, x_n mintából származó korrigált tapasztalati

szórásnégyzet legyen $S_n^{*2} := \frac{n}{n-1} S_n^2$.

A korrigált tapasztalati szórás legyen $S_n^* := \sqrt{S_n^{*2}}$.

Köv.: $E(S_n^{*2}) = \sigma^2$

Tétel: S_n^{*2} torzítatlan és konzisztens becslése σ^2 -nek.

10/12

Megj. 1: ~~csak~~ $S_n^* = \sqrt{S_n^{*2}}$ viszont NEM torzítatlan

becslése σ^2 -nek: $E\sqrt{S_n^{*2}} \neq \sqrt{E(S_n^{*2})}$.

A szórásnégyzet hasznosabb / kellemesebb fogalom, mint a szórás.

Megj. 2: $n=1$ esetben ~~sz~~ $S_n^2 = 0$, viszont $S_n^{*2} = \frac{1}{1-1} \cdot 0$

nincs értelme.

Ez így van jól: $n=1$ elemű mintából

- az hagyjón, hogy valaki várható értéket becsül
- de szórást már csak ne akarjon, pláne ne nullának.

Megj. 3: Mögöttes jelenség: Az n db adatunkból

- első lépésben megbeccsültük a várható értéket
- így 2. lépésben σ^2 becsléséhez "már csak $n-1$

szabadsági fokunk maradt" — ezért kell "n helyett $(n-1)$ -gyel osztani"
"független adat"

1.1/12

Megj: Mórcka rengeteg számot diktál 1-esével Pistikének
aztal, hogy számolja ki az átlagukat és a (korrigált)
tapasztalati szórás(négyzet)üket.

mit kerés a memóriájá

Pistike nem jegyzi meg a számokat, csak mindig az aktuális

• darabszámot: ehhez minden lépésben hozzáad 1-et

• összeget: ehhez $\frac{1}{n}$ ————— ja a legjobb számot

• négyzetösszeget: ehhez $\frac{1}{n}$ ————— legjobb szám négyzetét.

Az így történt 3 darab számból:

n -ből, $\sum_{i=1}^n x_i$ -ből és $\sum_{i=1}^n x_i^2$ -ből

bármikor könnyen számolható, ami kell:

$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$; $S_n^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2$; $S_n^{*2} = \frac{n}{n-1} S_n^2$

Sokkal könnyebben, mint ha az összes számból

számolná $S_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ alapján

~~Legy működik a klasszikus az seb~~ \uparrow az csak a legrosszab derül ki,

Igy működik a klasszikus zsdostatimológépek
statistika üzemmódja.

12/12