

Maximum likelihood becsles

1/11

Mintát veszünk az X val. változóból: x_1, x_2, \dots, x_n , és ez alapján szeretnénk kitalálni X eloszlását.

Könnyítés: Tudjuk, hogy X diszkrét, sőt, az eloszlását is ismerjük egy paraméter erejéig. [Avagy: adott egy 1-paraméteres eloszlás család.] Cél a paraméter megtalálása becslése.

Pl1: Tudjuk, hogy $X \sim B(p)$, csak p ismeretlen

Mondjuk onnan tudjuk, hogy $n=100$ -szor feldobtuk egy hamis érmet, és kijött, hogy FFIIFFIF...FIF
60 db F, 40 db I

Legyen $X = \begin{cases} 1, & \text{ha fej} \\ 0, & \text{ha nem} \end{cases}$ így a minta 11001011...1
60 db 1-es, 40 db 0

Ennek a konkrét mintának a valószínűsége

$$\prod_p (x_1, x_2, \dots, x_n) = \underbrace{p \cdot p \cdot (1-p) \cdot (1-p) \cdot p \cdot (1-p) \cdot p \cdot p \cdot \dots \cdot p}_{60 \text{ db } p, 40 \text{ db } (1-p)}$$

$$= p^{60} (1-p)^{40} \text{ persze függ a } p \text{ paramétertől!}$$

Pontosabban: $\prod_p (X_1=x_1, X_2=x_2, \dots, X_n=x_n)$

Nyilván: minél nagyobb az a valószínűség, annál kevésbé
„meglepő” az adott minta.

2/11

Def: A Likelihood-függvény nek nevezzük a

$P_p(X_1=x_1, X_2=x_2, \dots, X_n=x_n)$ valószínűséget, mint a p függvényt,

miközben az x_1, x_2, \dots, x_n mintát paraméternek tekintjük.

$$L(p) = L(\underbrace{x_1, x_2, \dots, x_n}_{\text{paraméterek}}; \underbrace{p}_{\text{változó}}) := P(X_1=x_1, \dots, X_n=x_n).$$

Esetünkben: $L(x_1, \dots, x_n; p) = p^{50} (1-p)^{40}$.

[Megj: Angolban likelihood \approx valószínűség, de nem keverendő a
probability = valószínűség szóval.]

[Magyarul lehetne mondjuk hihetőség-függvény...]

Def: A p paraméter maximum likelihood becslése a
likelihood-függvény (globális) maximumhelye.

[Vagyis az a $p = p_{ML}$, ahol $L(p)$ maximális, vagyis
amely p esetben az adott minta a legkevésbé meglepő /
leginkább hihető.]

Keressük meg ezt a p -t!

3/11

$$L(p) = p^{60} (1-p)^{40} \rightarrow \max$$

Éb lenne deriválni p szerint, de egy (sek-tényező's) szorzat deriválása elég csúnya: összeget könnyebb deriválni, ezért

$$l(p) := \ln L(p) = 60 \ln p + 40 \ln(1-p) \quad \text{a } \underline{\text{log-likelihood}} \text{ fv.}$$

Ennek nyilván ugyanott van a maximuma [mert $L \rightarrow \ln L$ szig. mon. növ.]

$$\text{vagyis } l(p) = 60 \ln p + 40 \ln(1-p) \rightarrow \max,$$

ezt már szívesebben deriválom, és a

$$l'(p) = 60 \cdot \frac{1}{p} + 40 \cdot \frac{1}{1-p} \cdot (-1) = \frac{60}{p} - \frac{40}{1-p} = 0$$

egyenletet kell megoldani

$$\frac{60}{p} = \frac{40}{1-p} \quad | \cdot p(1-p)$$

$$60(1-p) = 40p$$

$$60 - 60p = 40p \quad | + 60p$$

$$60 = 100p \quad | : 100$$

$$\underline{p = \frac{60}{100} = 0.6}$$

Mivel $l(p)$ -nek ez az egyetlen stationárius helye (ahol $l'(p)=0$), nyilván itt van az egyetlen maximum, vagyis $\boxed{P_{ML} = 0.6}$.

[Aki szeretné, ellenőrizheti a 2. deriválttal.]

Ugyanaztaltalános

legyen inkább f , mert a p többnyire jöjjön másra

Def: Legyen $P(X=x) = f(\theta; x)$, ahol $x \mapsto f(\theta; x)$

diszkrét valószínűségelosztás $\theta \in \mathbb{R}$ paraméterrel.
↳ ez nem is fontos

Legyen $x = (x_1, x_2, \dots, x_n)$ minta X -ből. Ekkor a

$$\theta \mapsto L(x_1, \dots, x_n; \theta) := \prod_{i=1}^n f(\theta; x_i) \quad \text{függvény}$$

~~h~~ θ paraméter változó

likelihood-függvények nevezünk, a z $L(\theta)$ globális maximumhelyét pedig a θ paraméter maximum likelihood becslésének. Fele: θ_{ML}

[Hát persze: ha a paraméter θ (lenne), akkor a minta valószínűsége $P(X_1=x_1, X_2=x_2, \dots, X_n=x_n) = \prod_{i=1}^n f(\theta; x_i)$ (lenne).]

[Az ~~a~~ ezé példában $\theta = p$, $f(\theta, x) = \begin{cases} \theta, & \text{ha } x=1 \\ 1-\theta, & \text{ha } x=0 \end{cases}$, és kivételesen hasznos az $f(\theta, x) = \theta^x (1-\theta)^{1-x}$ ($x=0,1$) zárt alak, így $L(x, \theta) = \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i}$.]

Röv: A leg-likelihood-függvény

$$l(\theta) = \ell(x; \theta) := \ln L(\theta) = \sum_{i=1}^n \ln f(\theta; x_i) \quad \text{maximuma is } \theta_{ML} \text{-nél van.}$$

Pl: $n=60$ demü mintát vettünk az $X \sim \text{Geom}(\theta)$
val. változóból, és az jött ki, hogy

$$(x_1, x_2, \dots, x_n) = (1, 1, 3, 1, 2, 1, \dots, 2)$$

60 db szám, az összegük 100 lett.

Adjunk maximum likelihood becslést θ -ra!

Megoldás: Az észlás ($\theta=p$ a statisztikus jelöléssel) $q=1-p$

~~$P(X=k) = q^{k-1} p = p(1-p)^{k-1}$~~ $k=1, 2, \dots$

vagyis $f(\theta; x) = P(X=x) = \theta(1-\theta)^{x-1}$ $x=1, 2, \dots$

$$\ln f(\theta; x) = \ln \theta + (x-1) \ln(1-\theta)$$

$$\Rightarrow \ell(x; \theta) = \sum_{i=1}^n \ln f(\theta; x_i) = \sum_{i=1}^n [\ln \theta + (x_i - 1) \ln(1-\theta)]$$

log-likelihood függvény

$$= n \ln \theta + \ln(1-\theta) \left[\sum_{i=1}^n x_i - n \right]$$

~~$= n \ln \theta + \ln(1-\theta) \left[\sum_{i=1}^n x_i - n \right]$~~

Keressük a maximumát: maximumhelyet:

$$\ell'(\theta) = n \cdot \frac{1}{\theta} + \left[\sum_{i=1}^n x_i - n \right] \cdot \frac{1}{1-\theta} \cdot (-1) = \frac{n}{\theta} - \frac{\sum_{i=1}^n x_i - n}{1-\theta} = 0$$

$$\frac{\sum_{i=1}^n x_i - n}{1-\theta} = \frac{n}{\theta} \quad | \cdot \theta(1-\theta)$$

$= \frac{1}{\bar{x}}$ hat perste

$$\theta \left(\sum_{i=1}^n x_i - n \right) = n - n\theta \quad | +n\theta$$

$$\theta \sum_{i=1}^n x_i = n \Rightarrow \theta_{ML} = \theta = \frac{n}{\sum_{i=1}^n x_i}$$

nyilván ez az egyetlen stat. hely maximumhely

A konkrét esetben $n=60$, $\sum_{i=1}^n x_i = 100 \Rightarrow \theta_{ML} = \frac{60}{100} = 0.6$ (6/11)

Hát persze:

- Az 1. példa arról szólta, hogy 100 dobásból 60 lett fej
- a 2. példa arról, hogy a 60-adik fej a 100-adik dobásra jött ki.

Folytonos eloszlások

Legyen X abszolút folytonos val.-értékű, sűrűségfüggvénye

$f(\theta; x)$, ahol θ ismeretlen paraméter.

$$P|: f(\theta; x) = \begin{cases} \theta e^{-\theta x}, & \text{ha } x \geq 0 \\ 0, & \text{ha } x < 0 \end{cases} \quad \text{vagyis } X \sim \text{Exp}(\theta).$$

Mintát veszünk X -ből, és az jön ki, hogy

$$\underline{x} = (0.9; 0.2; 4.3; 0.7; 1.1; 0.4; 1.4; 1.0)$$

Ekkor persze a konkrét \underline{x} minta valószínűsége nulla:

deve $P(X=0.9)=0$, de attól még, ha $f(\theta; x)$ nagy,

akkor az $\{X=x\}$ esemény „kevésbé meglepő”, mint ha

$f(\theta; x)$ kicsi (adott θ paraméter mellett). Ezért

Def: Legyen most is $L(\underline{x}; \theta) := \prod_{i=1}^n f(\theta; x_i)$ a likelihood-függvény, θ_{ML} pedig ennek maximumhelye.

Megj: Az $L(x; \theta) := \prod_{i=1}^n f(\theta; x_i)$ definíció első ránézésre ugyanaz a diszkrét és a folytonos esetben, de ez csak a szerencsétlen jelölés (em) miatt van:

- a folytonos esetben $f(x) = f(\theta; x)$ sűrűségfüggvény,
- a diszkrét esetben pedig diszkrét eloszlást jelöl.

A ~~fel~~ fenti példában

$$L(x; \theta) = \prod_{i=1}^n \theta e^{-\theta x_i}, \text{ mert szerencsére minden } x_i \geq 0$$

$$\ell(x; \theta) = \ln L(x; \theta) = \sum_{i=1}^n [\ln \theta - \theta x_i] = n \ln \theta - \theta \sum_{i=1}^n x_i$$

Megj: $\ln \ell(x; \theta) = \sum_{i=1}^n \ln f(\theta; x_i)$ ahol $\ln f(\theta; x_i) = \begin{cases} \ln \theta - \theta x, & \text{ha } x \geq 0 \\ \text{értelmetlen, ha} & x < 0 \end{cases}$

Vagyis ha valamelyik x_i negatív (lenne), akkor $L(x; \theta) = 0$, (minden θ -ra) (lenne), $\ell(x; \theta)$ pedig értelmetlen.

Hát persze: az ilyen minta lehetetlen: ha ez jön ki, akkor rossz a modell (vagy rossz a valóság).

(8/11)

Keressük $l(\theta)$ maximum helyét

$$l'(\theta) = \frac{n}{\theta} - \sum_{i=1}^n x_i = 0$$

$$\sum_{i=1}^n x_i = \frac{n}{\theta} \Rightarrow \left[\theta_{ML} = \theta = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}} \right]$$

[Nem meglepő: $EX = \frac{1}{\theta}$, és EX becslése \bar{x} .]

A konkrét esetben $n=8$, $\sum_{i=1}^8 x_i = 10.0 \Rightarrow \theta_{ML} = 0.8$.

Példa: Normális eloszlás paramétereinek M-L becslése

Legyen $X \sim N(m, \sigma)$, vagyis sűrűség függvénye

$$f_{m, \sigma}(x) = f(m, \sigma; x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}}$$

Mintát veszünk X -ből: $x = (x_1, x_2, \dots, x_n)$.

① Tfh σ ismert, mondjuk $\sigma=1$, így $\theta := m$ az egyetlen paraméter. Adjunk rá M-L becslést!

Megoldás: $\ln f(\theta; x) \stackrel{m=\theta}{\substack{\sigma \text{ ismert} \\ \text{konstans}}} \ln \frac{1}{\sqrt{2\pi}\sigma} - \frac{(x-\theta)^2}{2\sigma^2} = c - \frac{(x-\theta)^2}{2\sigma^2}$

$$\Rightarrow l(\theta) = \sum_{i=1}^n \ln f(\theta; x_i) = \sum_{i=1}^n \left[c - \frac{(x_i - \theta)^2}{2\sigma^2} \right] = nc - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2$$

maximum helyét keressük!

$$l'(\theta) = 0 - \frac{1}{2\sigma^2} \sum_{i=1}^n 2(x_i - \theta)(-1) = \frac{1}{\sigma^2} \left[\sum_{i=1}^n (x_i - \theta) \right] = 0 \quad \text{9/11} \\ / \cdot \sigma^2$$

$$n\theta = \sum_{i=1}^n x_i - n\theta = 0$$

$$\underline{\underline{\theta_{ML} = \frac{\sum_{i=1}^n x_i}{n} = \bar{x}}}} \quad \text{Hurrá,}$$

② Tfh m ismert, mondjuk $m=0$, így $\theta = \sigma$ az egyetlen paraméter. Adjunk rá M.L. becslést!

Megoldás: $\ln f(\theta; x) \stackrel{\sigma=0}{\text{m ismert}} = \underbrace{\ln \frac{1}{\sqrt{2\pi}}}_{\text{konstans}} - \ln \theta - \frac{(x-m)^2}{2\theta^2} = c - \ln \theta - \frac{(x-m)^2}{2\theta^2}$

$$\Rightarrow l(\theta) = \sum_{i=1}^n \ln f(\theta; x_i) = nc - n \ln \theta - \frac{1}{2\theta^2} \sum_{i=1}^n (x_i - m)^2$$

$$l'(\theta) = 0 - \frac{n}{\theta} - \frac{1}{2} \sum_{i=1}^n (x_i - m)^2 \left(-\frac{2}{\theta^3} \right) = 0 \quad / + \frac{n}{\theta}$$

$$\left[\text{mert } \left(\frac{1}{\theta^2} \right)' = \left(\theta^{-2} \right)' = -2\theta^{-3} = -\frac{2}{\theta^3} \right]$$

$$\frac{n}{\theta} = \frac{\sum_{i=1}^n (x_i - m)^2}{\theta^3} \quad / \cdot \theta^3/n$$

$$\theta^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2 \Rightarrow \boxed{\theta_{ML} = \sigma_{ML} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - m)^2}}$$

Hurrá.

2b) Legyen most is m ismert, de $\theta = \sigma^2 \neq \sigma$ az egyetlen paraméter. Most

$$l(\theta) = nc - n \ln \sqrt{\theta} - \frac{1}{2\theta} \sum_{i=1}^n (x_i - m)^2,$$

ami ugyanaz, mint az előbb, csak $\theta^2 \rightarrow \theta$ átjelöléssel

\Rightarrow a maximumhelye is „ugyanott” van:

$$\boxed{(\hat{\sigma}^2)_{ML} = (\hat{\sigma}_{ML})^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2} \quad \text{Hurrik.}$$

Ez éppen az m -től való négyzetes eltérés átlaga, stílusosul megfelel a $\sigma^2 = E((X-m)^2)$ definíciónak.

3) Sem m -et, sem σ -t nem ismerjük, így legyen a paraméter $\theta = (m, \sigma^2) = (m, \nu)$ vektor.
[várható érték és variancia].

Adjuk rá(juk) M.L becslést!

Megoldás: $f(\theta; x) = \frac{1}{\sqrt{2\pi\nu}} e^{-\frac{(x-m)^2}{2\nu}}$

$$\ln f(\theta; x) = -\ln(\sqrt{2\pi\nu}) - \frac{(x-m)^2}{2\nu} = \underbrace{-\ln\sqrt{2\pi}}_{\text{konstans}} - \frac{1}{2} \ln \nu - \frac{(x-m)^2}{2\nu}$$

$$\Rightarrow l(\theta) = l(m, \nu) = \sum_{i=1}^n \left[c - \frac{1}{2} \ln \nu - \frac{(x_i - m)^2}{2\nu} \right] = nc - \frac{n}{2} \ln \nu - \frac{1}{2\nu} \sum_{i=1}^n (x_i - m)^2$$

Vagyis

$$\boxed{\ell(\theta) = \ell(m, v) = \text{konstans} + \frac{n}{2} \ln v - \frac{1}{2v} \sum_{i=1}^n (x_i - m)^2} \quad \boxed{\ell: \mathbb{R}^2 \rightarrow \mathbb{R}}$$

11/11

még mindig ugyanaz, mint az előző 2 esetben, csak most kétváltozós fv-ként keressük a maximum helyét.

Ehhez legyen $\begin{cases} \frac{\partial \ell}{\partial m} = 0 \\ \frac{\partial \ell}{\partial v} = 0 \end{cases}$ egyenletrendszerre: ettől stacionárius hely az (m, v) pont.
 $\mathbb{D}_{\mathbb{R}^2}$

$$\frac{\partial \ell}{\partial m} = -\frac{1}{2v} \sum_{i=1}^n 2(x_i - m)(-1) = \frac{1}{v} \sum_{i=1}^n (x_i - m) = \frac{1}{v} \left[\sum_{i=1}^n x_i - nm \right]$$

$$\frac{\partial \ell}{\partial v} = -\frac{n}{2} \frac{1}{v} + \frac{1}{2v^2} \sum_{i=1}^n (x_i - m)^2 = \frac{1}{2v^2} \left[\sum_{i=1}^n (x_i - m)^2 - vn \right]$$

Vagyis meg kell oldani az alábbi egyenletrendszert:

$$\begin{cases} \frac{1}{v} \left[\sum_{i=1}^n x_i - nm \right] = 0 & \text{könnyű} \\ \frac{1}{2v^2} \left[\sum_{i=1}^n (x_i - m)^2 - vn \right] = 0 & \text{könnyű} \end{cases} \implies m = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$$\implies v = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

EGYBEN:

$$\boxed{(m, v)_{ML} = (\bar{x}, S_n^2)}$$

átlag

tapasztalati szórásnégyzet