

Kon ihåg:  $\bar{x}_1, \dots, \bar{x}_n$  är ett stickprov  
och vi vill skatta parametern  $\theta$ .

Def: Då  $\theta$  är okänd skriver vi

$f(x_1, \dots, x_n | \theta)$  för den gemensamma sf/dfkn  
för s.v.  $\bar{x}_1, \dots, \bar{x}_n$ .

Ann: I det diskreta fallet är kanske  
 $p(x_1, \dots, x_n | \theta)$  mer naturlig notation. Det  
blir dock opraktiskt med olika notationer  
för diskret/kont.

2) Om  $\bar{x}_1, \dots, \bar{x}_n$  är oberoende får vi att  
 $f(x_1, \dots, x_n | \theta) = f(x_1 | \theta) \dots f(x_n | \theta)$ .

3) Vi skriver  $f(\cdot | \theta)$  för att påminna  
att  $\theta = (\theta_1, \dots, \theta_m)$  är okänd.

Def: Givet observerade data  $x_1, \dots, x_n$   
(dvs  $\bar{x}_1 = x_1, \bar{x}_2 = x_2, \dots, \bar{x}_n = x_n$ ) definierar vi  
likeligheten av  $\theta$  som

$$\text{lik}(\theta) = f(x_1, \dots, x_n | \theta)$$

Ann: <sup>1)</sup> Observera att  $lik(\theta)$  ses som en funktion av  $\theta$ , ej  $x_1, \dots, x_n$ .

<sup>2)</sup> Om  $\underline{x}_i$  är diskreta så blir

$$lik(\theta) = f(x_1, \dots, x_n | \theta) = \mathbb{P}(\underline{X}_1 = x_1 | \theta) \cdots \mathbb{P}(\underline{X}_n = x_n | \theta).$$

Alltså är  $lik(\theta)$  sann. att få de givna värdena  $x_1, \dots, x_n$  som funktion av  $\theta$ .

Def: ML-skattaren (Maximum Likelihood Estimator, MLE) av  $\theta$  är det värde  $\hat{\theta}$  som maximerar  $lik(\theta)$ .

Ann: <sup>1)</sup> I det diskreta fallet är  $\hat{\theta}$  det värde på  $\theta$  som gör de observerade data mest troligt (most likely).

<sup>2)</sup> Det kont. fallet är mer svårtolkat.

Vi kommer alltså vilja maximera  $lik(\theta)$ . Ofta är det enklast att maximera

$$l(\theta) = \log(lik(\theta)) = \sum_{i=1}^n \log(f(x_i | \theta))$$

Ann:  $0 < \bar{x}_1 = x_1, \dots, \bar{x}_n = x_n$  är alltså

$$\text{lik}(\theta) = \prod_{i=1}^n f(x_i | \theta) = \text{lik}(\theta, x_1, \dots, x_n)$$

Man skriver ofta

$$\text{lik}(\theta) = \prod_{i=1}^n f(\bar{x}_i | \theta) = \text{lik}(\theta, \bar{x}_1, \dots, \bar{x}_n).$$

Detta är analogt med  $\mathbb{E}[\bar{X} | \Sigma]$  det. av

$$\mathbb{E}[\bar{X} | \Sigma = \gamma] \quad \forall \gamma.$$

Tal: Låt  $\bar{x}_1, \dots, \bar{x}_n$  vara iid  $\text{Poi}(\lambda)$ .

a) Hitta MME  $\hat{\lambda}$ .

b) Hitta MLE  $\hat{\lambda}$ .

L: a) Då  $\bar{x}_i \sim \text{Poi}(\lambda)$  är  $\mathbb{E}[\bar{x}_i] = \lambda$

MME: Lös  $\bar{\bar{x}} = \hat{\lambda}$  (trivialt) så  $\hat{\lambda} = \bar{\bar{x}}$ .

b) Vi har att

$$\text{lik}(\lambda) = l(k_1, \dots, k_n | \lambda) = \prod_{i=1}^n l(k_i | \lambda) = \prod_{i=1}^n \frac{\lambda^{k_i}}{k_i!} e^{-\lambda},$$

alternativt

$$\text{lik}(\lambda) = \prod_{i=1}^n \frac{\lambda^{\bar{x}_i}}{\bar{x}_i!} e^{-\lambda}$$

$$\Rightarrow l(\lambda) = \log(\text{lik}(\lambda)) = \sum_{i=1}^n (\bar{x}_i \log \lambda - \log \bar{x}_i! - \lambda)$$

$$= \log \lambda \sum_{i=1}^n \bar{x}_i - n\lambda - \sum_{i=1}^n \log \bar{x}_i!$$

Detta skall maximeras:

$$l'(\lambda) = \frac{1}{\lambda} \sum_{i=1}^n \bar{x}_i - n$$

$$l''(\lambda) = -\frac{1}{\lambda^2} \sum_{i=1}^n \bar{x}_i < 0 \quad \text{om} \quad \sum_{i=1}^n \bar{x}_i \neq 0$$

Så  $l'(\lambda) = 0 \Rightarrow \lambda = \frac{1}{n} \sum_{i=1}^n \bar{x}_i = \bar{\bar{x}}$  om  $\sum_{i=1}^n \bar{x}_i \neq 0$

och  $l''(\lambda) < 0$  ger att  $\hat{\lambda} = \bar{\bar{x}}$  maximerar  $l(\lambda)$ .

Om nu  $\sum_{i=1}^n \bar{x}_i = 0 \Rightarrow l(\lambda) = e^{-n\lambda}$  maximeras av

$\lambda = 0$ , så att återigen blir  $\hat{\lambda} = \bar{\bar{x}}$ .

Tal: Låt  $\bar{x}_1, \bar{x}_2, \dots$  vara i.i.d.  $\mathcal{N}(\mu, \sigma^2)$ .

a) Hitta MME för  $\mu, \sigma^2$

b) Hitta MLE för  $\mu, \sigma$ . ← subtilt men viktigt!

L: Vi har att  $\mathbb{E}[\bar{x}] = \mu$  och

$$\mathbb{E}[\bar{x}^2] = \text{Var}(\bar{x}) + \mathbb{E}[\bar{x}]^2 = \sigma^2 + \mu^2.$$

Enligt Momentmetoden skall vi sätta

$$\bar{\bar{x}} = \hat{\mu} \quad \text{och}$$

$$\overline{\bar{x}^2} = \hat{\sigma}^2 + \hat{\mu}^2$$

$$\begin{aligned} \Rightarrow \hat{\sigma}^2 &= \overline{\bar{x}^2} - \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n \bar{x}_i^2 - \left( \frac{1}{n} \sum_{i=1}^n \bar{x}_i \right)^2 \\ &= \frac{1}{n} \left( \sum_{i=1}^n \bar{x}_i^2 - n \bar{\bar{x}}^2 \right) = \frac{1}{n} \sum_{i=1}^n (\bar{x}_i^2 + \bar{\bar{x}}^2 - 2\bar{x}_i \bar{\bar{x}}) \\ &= \frac{1}{n} \sum_{i=1}^n (\bar{x}_i - \bar{\bar{x}})^2 // \end{aligned}$$

b)

Vi har att om  $\bar{x}_i \sim \mathcal{N}(\mu, \sigma^2)$ 

$$f(x_1, \dots, x_n | \mu, \sigma) = \prod_{i=1}^n \frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{1}{2} \frac{(x_i - \mu)^2}{\sigma^2}\right)$$

$$\Rightarrow \ell(\mu, \sigma) = \sum_{i=1}^n \log\left(\frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{1}{2} \frac{(x_i - \mu)^2}{\sigma^2}\right)\right)$$

$$= -n \log \sigma - n \log \sqrt{2\pi} - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

Vi hittar maximum:

$$\frac{\partial \ell}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)$$

$$\frac{\partial \ell}{\partial \sigma} = -\frac{n}{\sigma} + \frac{1}{\sigma^3} \sum_{i=1}^n (x_i - \mu)^2$$

$$\text{s. a. } \frac{\partial \ell}{\partial \mu} = 0 \Rightarrow 0 = \sum_{i=1}^n (x_i - \mu) = -n\mu + \sum_{i=1}^n x_i$$

$$\Rightarrow \mu = \bar{x}$$

vidare är

$$0 = \frac{\partial \ell}{\partial \sigma} = -\frac{n}{\sigma} + \frac{1}{\sigma^3} \sum_{i=1}^n (x_i - \mu)^2 = \left\{ \mu = \bar{x} \right\}$$

$$= -\frac{n}{\sigma} + \frac{1}{\sigma^3} \sum_{i=1}^n (x_i - \bar{x})^2 \Rightarrow \hat{\sigma} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$

D.v.s.  $\hat{\mu} = \bar{x}$  och  $\hat{\sigma} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$ .

Ann: MLE för  $\sigma^2$  (dvs  $\hat{\sigma}^2$ ) blir

$$\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad \text{dvs} \quad (\hat{\sigma})^2. \quad \text{Detta följer}$$

$$\text{av att} \quad \frac{\partial \ell}{\partial \sigma^2} = \frac{\partial \ell}{\partial \sigma} \cdot \frac{\partial \sigma}{\partial \sigma^2} = \frac{\partial \ell}{\partial \sigma} \cdot \frac{1}{\frac{\partial \sigma^2}{\partial \sigma}} = \frac{\partial \ell}{\partial \sigma} \cdot \frac{1}{2\sigma}$$

$$\Gamma_{\sigma^2} \text{ s.a. } \left( \frac{\partial \ell}{\partial \sigma} \cdot \frac{1}{2\sigma} \right) (\sigma^2) = 0 \quad \text{samma } \sigma^2 \text{ s.a. } \frac{\partial \ell}{\partial \sigma^2} (\sigma^2) = 0$$

$$\Rightarrow \frac{\partial \ell}{\partial \sigma^2} (\sigma^2) = 0 \quad \text{där vi ser } \frac{\partial \ell}{\partial \sigma^2} \text{ som funkt. av } \sigma^2!$$

2) MME för  $\sigma$  är samma som  $\sqrt{\hat{\sigma}^2}$

3)  $E[\hat{\sigma}^2] = E\left[\frac{n-1}{n} \cdot s^2\right] = \frac{n-1}{n} \sigma^2$  så ej VVR!

Observera även att (med  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ )

$$E[s] = E[\sqrt{s^2}] \neq \sqrt{E[s^2]} = \sqrt{\sigma^2} = \sigma \quad \text{så}$$

$s$  är ej en VVR skattare för  $\sigma$ .

I allmänhet  $E[\sqrt{X}] \leq \sqrt{E[X]}$  om  $X \geq 0$ .