

II.) Metoda maximální věrohodnosti

X_1, \dots, X_n je máh. výběr \Rightarrow hustota $f(x, \Theta)$, tj. X_i má hustotu (pravd. funkci) $f(x, \Theta)$, kde $\Theta \in \mathbb{R}^p$ je nerný parametr

sdružená hustota máh. vektoru $(X_1, \dots, X_n)^T$ je $L(\Theta) = L(\Theta, X_1, \dots, X_n) = \prod_{i=1}^n f(x_i, \Theta)$... funkce Θ (věrohodnostní funkce)

$\hat{\Theta} = \hat{\Theta}(X_1, \dots, X_n)$ je odhad parametru Θ metodou max. věrohodnosti, jestliže $L(\hat{\Theta}) \geq L(\Theta), \forall \Theta$, tj. $\hat{\Theta} = \underset{\Theta}{\operatorname{argmax}} L(\Theta)$.

$l(\Theta) = \log L(\Theta) = \sum_{i=1}^n \log f(x_i, \Theta)$... logaritmická věrohodnostní funkce $\hat{\Theta} = \underset{\Theta}{\operatorname{argmax}} l(\Theta)$.



Příklad (motivace MLE)

Hodíme 3x Jaleňonovými mincemi. Víme, že pravd. je v daném hodě padne líce je buďto $p_1 = 0,2$ nebo $p_2 = 0,6$. 2 krát 3 hodů padl 1 líce.

Otázka: Je pravděpodobnost padnutí líce p_1 nebo p_2 ?

model: $X =$ počet padnutí líce, $X \sim \text{Bi}(3, p)$, kde $p =$ pravděpodobnost, že v 1 hodě padne líce $p = p_1$ nebo $p = p_2$.

$$P(x) = P(X=x) = \binom{3}{x} p^x (1-p)^{3-x}, x=0,1,2,3$$



"MLE nemůže poskytnout realizaci máh. výběru nejvíce podobný hodnotu parametru", tedy MLE parametru p je $\hat{p} = p_1 = 0,2$.

Charakteristika max. věrohodných odhadů

Za určitých předpokladů (podmínky regularity) jsou max. věrohodné odhady asymptoticky nezávislé, konzistentní a asymptoticky normální:

$$\sqrt{m}(\hat{\theta} - \theta) \approx N_P(\theta, \mathbb{J}^{-1}(\theta)), \text{ kde } \mathbb{J}(\theta) = \left(E \frac{\partial \log f(X_i, \theta)}{\partial \theta_i} \cdot \frac{\partial \log f(X_i, \theta)}{\partial \theta_j} \right)_{i,j=1}^P$$

je Fisherova informační matice
o parametru θ příslušná X_i

$$= \left\{ - E \left(\frac{\partial^2 \log f(X_i, \theta)}{\partial \theta_i \partial \theta_j} \right) \right\}_{i,j=1}^P$$

Pozn.

$$\hat{\theta} \approx N_P\left(\theta, \frac{\mathbb{J}^{-1}(\theta)}{m}\right)$$

Příklad (počet úmrtí při dopravních nehodách)

Studujeme počty smrtelných zranění při dopravních nehodách v ČR od 29.6.2015 do 28.7.2015 (celkem 30 dní)

počet úmrtí	0	1	2	3	4	5	6	7	8	9	10
počet dní	4	6	6	8	3	0	2	0	0	0	1

Chceme odhadnout ^{předpoklad} že se dnes setkáme s určitou smrtelnou nehodou = P.

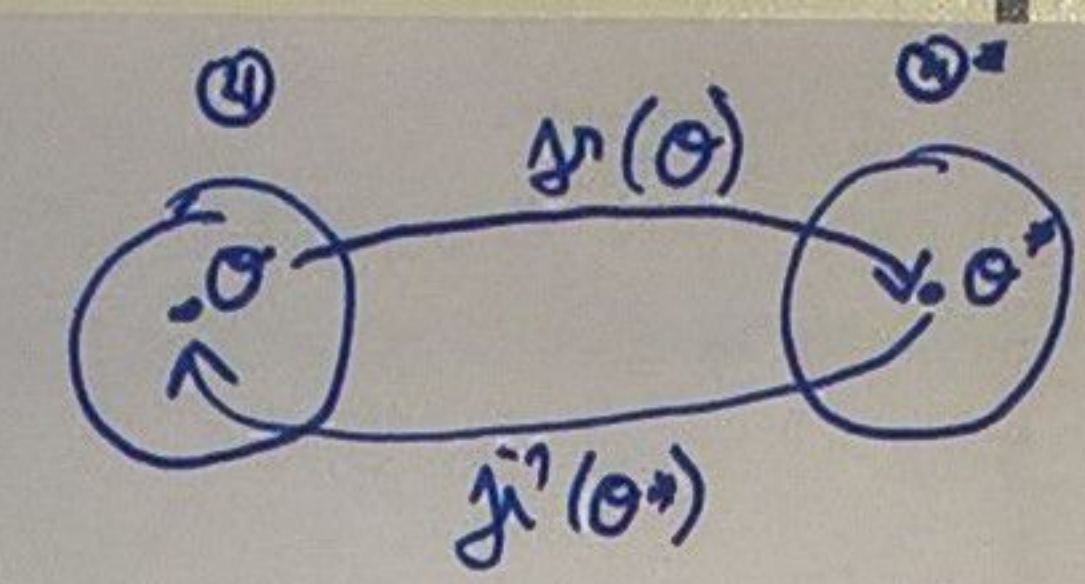
neparametrický model: empirický odhad $\hat{p} = \frac{\text{počet dní bez smrtelné nehody}}{\text{počet dní}} = \frac{4}{30} \approx 0,13$.

parametrický model: $X_i =$ počet smrtelných zranění i -tý den; X_1, \dots, X_{30} má stejný rozdělení z $Po(\lambda)$ $\lambda =$ průměrný počet smrtelných zranění za 1 den

má nejvyšší parametrické funkce $f_0(\lambda) = e^{-\lambda} = P(X_i = 0)$.

Maximální věrohodný odhad parametrické funkce $y: \mathbb{R}^p \rightarrow \mathbb{R}$.

necht $y: \mathbb{H} \rightarrow \mathbb{H}^*$ je prosta funkce



Funkce $\tilde{L}(\theta^*) = \prod_{i=1}^m f(x_i, y^{-1}(\theta^*)) = L(y^{-1}(\theta^*))$ pro $\theta^* \in \mathbb{H}^*$ je max. věrohodnostní funkce indukovaná parametrickou funkcí y .

$\hat{\theta}^*$ je max. věrohodný odhad $\text{je } y(\hat{\theta}) = \theta^*$, jestliže $\tilde{L}(\hat{\theta}^*) \geq \tilde{L}(\theta^*)$, $\forall \theta^* \in \mathbb{H}^*$.

Uvazeni (Lehmannova věta, princip invariance MLE)

je-li $\hat{\theta}$ max. věr. odhadem parametru θ , pak $y(\hat{\theta})$ je max. věr. odhadem parametrické funkce $y(\theta)$.

Delta (delta metoda)

Necht $\{X_n\}_{n=1}^{\infty}$ je posloupnost p -rozměrných náh. vektorů X_n takových, že $\sqrt{n}(X_n - \theta) \approx N_p(\theta, \Sigma)$. Dále buď $y: \mathbb{R}^p \rightarrow \mathbb{R}$ měřitelná zobrazení, které má totální diferenciál v bodě θ . Pak platí $\sqrt{n}(y(X_n) - y(\theta)) \approx N(0, \sigma^2)$, kde $\sigma^2 = \nabla y(\theta)^T \Sigma \nabla y(\theta)$ a

$\nabla y(\theta) = \left(\frac{\partial y(\theta)}{\partial \theta_1}, \dots, \frac{\partial y(\theta)}{\partial \theta_p} \right)^T$ je gradient funkce y v bodě θ .

Důsledky (pro MLE)

za určitých předpokladů (podmínky regularity) a necht $y: \mathbb{R}^p \rightarrow \mathbb{R}$ je prosta. Pak $\sqrt{n}(y(\hat{\theta}) - y(\theta)) \approx N(0, \nabla y(\theta)^T J^{-1}(\theta) \nabla y(\theta))$.

Poznámka

$y(\hat{\theta})$ je as. nekorelovaný, konzistentní odhad $y(\theta)$. Matice $J(\hat{\theta}) \approx N(y(\theta), \frac{\nabla y(\theta)^T J^{-1}(\theta) \nabla y(\theta)}{n})$

σ jednorozměrný parametr, tj. $p=1$

$$y(\hat{\theta}) \approx N\left(y(\theta), \frac{[y'(\theta)]^2}{n J(\theta)}\right)$$

Úkollad (metody - počítání)

X_1, \dots, X_m máh. syst. z $P_0(\lambda)$, $\lambda > 0$ neznámý parametr

$$P(x, \lambda) = f(x, \lambda) = P(X=x) = e^{-\lambda} \cdot \frac{\lambda^x}{x!}, \quad x=0, 1, \dots$$

$$\log f(x, \lambda) = -\lambda + x \log \lambda - \log x!$$

$$l(\lambda) = \sum_{i=1}^m \log f(x_i, \lambda) = -m\lambda + \log \lambda \sum_{i=1}^m x_i - \sum_{i=1}^m \log x_i!$$

$$l'(\lambda) = -m + \frac{\sum_{i=1}^m x_i}{\lambda} \stackrel{!}{=} 0$$

$$\lambda = \frac{1}{m} \sum_{i=1}^m x_i \Rightarrow \hat{\lambda} = \bar{X} \text{ je odhad parametru } \lambda$$

Plasknutí $\hat{\lambda}$?

• podle CLV je $\hat{\lambda} \approx N(\lambda, \frac{1}{m})$

• podle levice MLE

$$J(\lambda) = E \left(\frac{\partial \log f(X_i, \lambda)}{\partial \lambda} \right)^2 = -E \frac{\partial^2 \log f(X_i, \lambda)}{\partial \lambda^2}$$

$$\left. \begin{aligned} \frac{\partial \log f(x_i, \lambda)}{\partial \lambda} &= -1 + \frac{x_i}{\lambda} \\ \frac{\partial^2 \log f(x_i, \lambda)}{\partial \lambda^2} &= -\frac{x_i}{\lambda^2} \end{aligned} \right\} J(\lambda) = E \frac{x_i}{\lambda^2} = \frac{E x_i}{\lambda^2} = \frac{1}{\lambda^2} = \frac{1}{\lambda}$$

$$\hat{\Theta} \approx N(\Theta, \frac{1}{m J(\Theta)}) \quad \text{v našem případě } \hat{\lambda} \approx N(\lambda, \frac{1}{m})$$

Nyní již můžeme přejít k našemu problému, odhad parametrické funkce $g(\lambda) = e^{-\lambda}$. Její MLE je $\hat{e} = e^{-\hat{\lambda}} = e^{-\bar{X}}$.

Spočítáme bodovou odhadu pro naše data: $\hat{\lambda} = \bar{x} = 2,53$ a $\hat{e} = P(X_i=0) = e^{-2,53} = 0,079$. Jak moc jmo niklím jistí? \Rightarrow interval spolehlivosti

$[D(X_1, \dots, X_m), H(X_1, \dots, X_m)]$ je $100(1-\alpha)\%$ IS pro param. funkci $g(\lambda)$, jestliže $P(D(X_1, \dots, X_m) \leq g(\lambda) \leq H(X_1, \dots, X_m)) = 1-\alpha, \forall \lambda$.

$$\begin{aligned} g(\lambda) &= e^{-\lambda} \\ g'(\lambda) &= -e^{-\lambda} \\ [g'(\lambda)]^2 &= e^{-2\lambda} \\ J(\lambda) &= \frac{1}{\lambda} \end{aligned}$$

$$\begin{aligned} \hat{e} &\approx N\left(e^{-\lambda}, \frac{e^{-2\lambda}}{m}\right) \\ \frac{\hat{e} - e^{-\lambda}}{\sqrt{\frac{1 \cdot e^{-2\lambda}}{m}}} &\approx N(0, 1) \end{aligned}$$

- není pivotová statistika

Cramér-Šlubsky

$$\frac{\hat{e} - e^{-\lambda}}{\sqrt{\frac{\bar{x} \cdot e^{-2\bar{x}}}{m}}} \approx N(0, 1)$$

pivotová statistika

\Rightarrow Nyní již můžeme asymptotický IS sestavit.

$$\left[\frac{\bar{x}}{l} - U_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{x} \cdot e^{-2\bar{x}}}{m}}, \frac{\bar{x}}{l} + U_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{x} \cdot e^{-2\bar{x}}}{m}} \right] \text{ je hledaný } (1-\alpha) \cdot 100 \% \text{ interval spolehlivosti pro } \bar{l}^{-1}.$$

σ mámen případě: $[0,034; 0,125]$.

Na záměr vyšetřít poroovně neparamečičm modelm (bez předpokladu Poissonova rozdělení)

$Y_i < 1$ i-tý den se ~~stane~~ nastane zádná nehoda
 $Y_i < 0$ jinak

$Y_i \sim A(p)$, $p = P(\text{od daný den se nastane zádná nehoda})$, $p \in (0,1)$ je neznámý parametr

bodový odhad p je $\hat{p} = \bar{Y} = \frac{1}{m} \sum_{i=1}^m Y_i = \frac{4}{30} = 0,13$.

$$\bar{Y} \approx N\left(p, \frac{p(1-p)}{m}\right)$$

$$\frac{\bar{Y} - p}{\sqrt{\frac{p(1-p)}{m}}} \approx N(0,1) \quad \frac{\bar{Y} - p}{\sqrt{\frac{\bar{Y}(1-\bar{Y})}{m}}} \approx N(0,1) \xrightarrow{\text{hledání IS je}} \left[\bar{Y} - U_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{Y}(1-\bar{Y})}{m}}, \bar{Y} + U_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{Y}(1-\bar{Y})}{m}} \right]$$

a konečné proměnné data: $[0,012; 0,255]$.