

Vlastnosti estimátorů

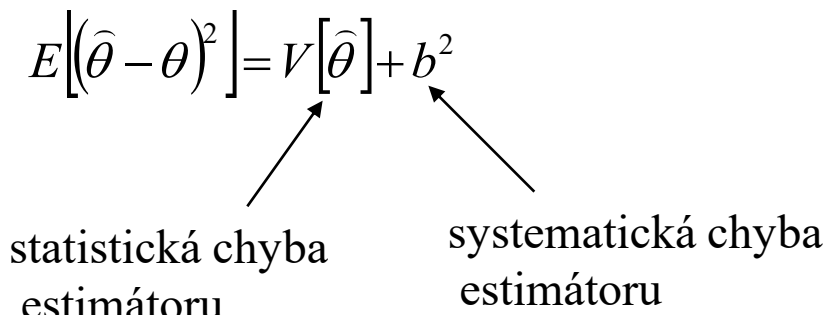
1. konzistence

- pro $n \rightarrow \infty$ konverguje $\vec{\hat{\theta}}$ k $\vec{\theta}$ $\lim_{n \rightarrow \infty} P(|\vec{\hat{\theta}} - \vec{\theta}| > \varepsilon) = 0$

2. předpojatost

- předpojatost $b \equiv E[\hat{\theta}] - \theta$
- $b = 0 \Rightarrow$ nepředpojatý (nevychýlený) odhad

3. efektivita

- MSE: $E[(\hat{\theta} - \theta)^2] = V[\hat{\theta}] + b^2$


statistická chyba
estimátoru

systematická chyba
estimátoru

Metoda maximální věrohodnosti

- sada n naměřených hodnot x_i : $\vec{x} = (x_1, x_2, \dots, x_n)$ $x_i \in f(x | \vec{\theta})$ x_i nezávislé
- parametry: $\vec{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$
- cíl – najít nejlepší odhad $\vec{\theta}$ parametrů $\vec{\theta}$
- odhad (estimátor) $\vec{\hat{\theta}} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m)$

-
- pravděpodobnost $P\{x \in (x_i, x_i + dx)\} = f(x_i | \vec{\theta}) dx$
 - pravděpodobnost, že naměříme hodnoty (x_1, x_2, \dots, x_n) : $P = \prod_{i=1}^n f(x_i | \vec{\theta}) dx$

věrohodnostní funkce $L(\vec{\theta} | \vec{x}) \equiv \prod_{i=1}^n f(x_i | \vec{\theta})$

- hledáme hodnoty $\vec{\hat{\theta}}$ pro které L nabývá maximum

$$\frac{\partial L}{\partial \theta_k} = 0, \quad k = 1, 2, \dots, m \quad \Rightarrow \quad \hat{\theta}_k$$

Odhad parametrů normálního rozdělení

- naměřené hodnoty: $\vec{x} = (x_1, x_2, \dots, x_n)$

- hustota pravděpodobnosti: $f(x | \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left[\frac{-(x - \mu)^2}{2\sigma^2}\right]$

- věrohodnostní funkce: $L(\mu, \sigma | \vec{x}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma}} \exp\left[\frac{-(x_i - \mu)^2}{2\sigma^2}\right]$

$$\ln L(\mu, \sigma | \vec{x}) = \sum_{i=1}^n \frac{-(x_i - \mu)^2}{2\sigma^2} - \sum_{i=1}^n \ln(\sqrt{2\pi\sigma})$$

- odhad očekávané hodnoty: $\frac{\partial \ln L}{\partial \mu} \Big|_{\mu=\hat{\mu}} = 0 \Rightarrow \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i$

- odhad rozptylu: $\frac{\partial \ln L}{\partial \sigma} \Big|_{\sigma=\hat{\sigma}} = 0 \Rightarrow \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$

Musíme znát skutečnou očekávanou hodnotu

Odhad parametrů normálního rozdělení

- odhad očekávané hodnoty: $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i \equiv \bar{x}$ (aritmetický průměr)

- odhad rozptylu: $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \approx \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \equiv s_0^2$

- předpojatost?

$$E[\hat{\mu}] = \frac{1}{n} \sum_{i=1}^n E[x_i] = \mu \quad \Rightarrow \text{nepředpojatý odhad}$$

$$E[\hat{\sigma}^2] = \frac{1}{n} \sum_{i=1}^n E[(x_i - \mu)^2] = \sigma^2 \quad \Rightarrow \text{nepředpojatý odhad}$$

ale

$$E[s_0^2] = \frac{1}{n} \sum_{i=1}^n E[(x_i - \bar{x})^2] = \frac{n-1}{n} \sigma^2 \quad \Rightarrow \text{předpojatý odhad}$$

- nepředpojatý odhad rozptylu: $s_1^2 \equiv \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

Metoda nejmenších čtverců

x_1, x_2, \dots, x_N

y_1, y_2, \dots, y_N

$\lambda(x | \vec{\theta})$

$y_i \in N(\lambda_i, \sigma_i)$

$\vec{\theta} = (\theta_1, \dots, \theta_m)$

• experimentální data

• modelová funkce

x – nezávislá proměnná

y – závislá proměnná


$$L(\vec{\theta} | \vec{y}) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(y_i - \lambda(x_i | \vec{\theta}))^2}{2\sigma_i^2}\right]$$

• věrohodnostní funkce

$$\ln L(\vec{\theta} | \vec{y}) = -\sum_{i=1}^N \frac{(y_i - \lambda(x_i | \vec{\theta}))^2}{2\sigma_i^2} - \sum_{i=1}^N \ln \sqrt{2\pi}\sigma_i$$

$$\chi^2(\vec{\theta} | \vec{y}) = \sum_{i=1}^N \frac{(y_i - \lambda(x_i | \vec{\theta}))^2}{\sigma_i^2}$$

• minimalizace χ^2



Metoda nejmenších čtverců – lineární fit $y = m x$


$$\lambda(x | m) = mx$$

$$\chi^2(m | \vec{y}) = \sum_{i=1}^N \frac{(y_i - mx_i)^2}{\sigma_i^2}$$

$$\hat{m} = \frac{\sum_{i=1}^N \frac{y_i x_i}{\sigma_i^2}}{\sum_{i=1}^N \frac{x_i^2}{\sigma_i^2}} = \frac{\langle xy \rangle}{\langle x^2 \rangle}$$

$$V[\hat{m}] = \frac{1}{\sum_{i=1}^N \frac{x_i^2}{\sigma_i^2}} = \frac{1}{\langle x^2 \rangle}$$

označení: $\langle a \rangle \equiv \sum_{i=1}^N \frac{a_i}{\sigma_i^2}$



Metoda nejmenších čtverců – vyjádření pomocí matic

$$x_1, x_2, \dots, x_N$$

$$y_1, y_2, \dots, y_N \quad y_i \in N(\lambda_i, \sigma_i)$$

$$\lambda = \lambda(x | \bar{\theta}) \quad \bar{\theta} = (\theta_1, \dots, \theta_m) \quad \text{lineární model}$$

$$\lambda(x_i | \bar{\theta}) = \sum_{j=1}^m a_j(x_i) \theta_j = \sum_{j=1}^m A_{ij} \theta_j$$

$$\boldsymbol{\lambda} = \mathbf{A} \boldsymbol{\theta}$$

$$\chi^2 = \sum_{i=1}^n \frac{\left(y_i - \sum_{j=1}^m A_{ij} \theta_j \right)^2}{\sigma_i^2}$$

pokud $\sigma_i = \sigma$ ↓

$$\chi^2 = \frac{1}{\sigma^2} (\mathbf{y} - \mathbf{A} \boldsymbol{\theta})^T (\mathbf{y} - \mathbf{A} \boldsymbol{\theta})$$

obecně \mathbf{V} , $V_{ij} = \text{cov}(y_i, y_j)$

$$\chi^2 = (\mathbf{y} - \mathbf{A} \boldsymbol{\theta})^T \mathbf{V}^{-1} (\mathbf{y} - \mathbf{A} \boldsymbol{\theta})$$

$$\frac{\partial \chi^2}{\partial \theta_k} = -\frac{2}{\sigma^2} \sum_{i=1}^N \left(y_i - \sum_{j=1}^m A_{ij} \theta_j \right) A_{ik}$$

$$\frac{\partial \chi^2}{\partial \theta_k} = 0 \quad \downarrow$$

$$\sum_{i=1}^N A_{ik} y_i = \sum_{i=1}^N \sum_{j=1}^m A_{ik} A_{ij} \theta_j$$

$$\mathbf{A}^T \mathbf{y} = \mathbf{A}^T \mathbf{A} \boldsymbol{\theta}$$

$$\hat{\boldsymbol{\theta}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y} \equiv \mathbf{B} \mathbf{y}$$

$$\hat{\boldsymbol{\theta}} = (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} \equiv \mathbf{B} \mathbf{y}$$

$$\mathbf{U}, \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j)$$

$$\mathbf{U} = \mathbf{B} \mathbf{V} \mathbf{B}^T$$

$$(U^{-1})_{ij} = \frac{1}{2} \left[\frac{\partial^2 \chi^2}{\partial \theta_i \partial \theta_j} \right]_{\bar{\theta} = \hat{\bar{\theta}}}$$

Metoda nejmenších čtverců – fit polynomu

$$\lambda(x_i | \vec{\theta}) = \sum_{j=1}^m x_i^j \theta_j = \sum_{j=1}^m A_{ij} \theta_j$$

$$\vec{\theta} = (\theta_1, \dots, \theta_m) \quad \sigma_i \equiv \sigma$$

$$A_{ij} = x_i^j$$

$$\mathbf{A} = \begin{pmatrix} 1 & x_1 & x_1^2 & \dots & x_1^m \\ 1 & x_2 & x_2^2 & \dots & x_2^m \\ \dots & & & & \\ 1 & x_N & x_N^2 & \dots & x_N^m \end{pmatrix} \quad N \times m$$

$$\mathbf{A}^T \mathbf{A} = \begin{pmatrix} N & \sum_{i=1}^N x_i & \sum_{i=1}^N x_i^2 & \dots & \sum_{i=1}^N x_i^m \\ \sum_{i=1}^N x_i & \sum_{i=1}^N x_i^2 & \sum_{i=1}^N x_i^3 & \dots & \sum_{i=1}^N x_i^{m+1} \\ \dots & & & & \\ \sum_{i=1}^N x_i^m & \sum_{i=1}^N x_i^{m+1} & \sum_{i=1}^N x_i^{m+2} & \dots & \sum_{i=1}^N x_i^{m+m} \end{pmatrix} \quad m \times m$$

$$\hat{\theta} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y}$$

Metoda nejmenších čtverců – fit paraboly

$$\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A} = \begin{pmatrix} \sum_{i=1}^N \frac{1}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^4}{\sigma_i^2} \end{pmatrix}$$

$$\lambda(x|\theta) = \theta_0 + \theta_1 x + \theta_2 x^2$$

$$\theta_0 = 140 \pm 50$$


$$\theta_1 = 92 \pm 5$$

$$\theta_2 = -1.8 \pm 0.1$$

$$\hat{\boldsymbol{\theta}} = (\mathbf{A}^T \mathbf{V}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{V}^{-1} \mathbf{y} \equiv \mathbf{B} \mathbf{y}$$

$$\mathbf{U}, \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j)$$

$$\mathbf{U} = \mathbf{B} \mathbf{V}^{-1} \mathbf{B}^T$$



Fit histogramu

$$x_1, x_2, \dots, x_N \quad f(x|\boldsymbol{\theta}) \quad \boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_M)$$

• místo $x_1, x_2, \dots, x_N \longrightarrow$ histogram K binů $\mathbf{n} = (n_1, n_2, \dots, n_K)$

• pravděpodobnost, že výsledek padne do i -tého binu: $P_i = \int_{x_i - \frac{\Delta}{2}}^{x_i + \frac{\Delta}{2}} f(x|\boldsymbol{\theta}) dx$


• očekávaná hodnota v i -tém binu: $v_i(\boldsymbol{\theta}) = NP_i = N \int_{x_i - \frac{\Delta}{2}}^{x_i + \frac{\Delta}{2}} f(x|\boldsymbol{\theta}) dx$

• věrohodnost:



$$L(\boldsymbol{\theta}) = P(\mathbf{n}|\mathbf{v}) = \frac{N!}{n_1! n_2! \dots n_K!} \left(\frac{v_1(\boldsymbol{\theta})}{N} \right)^{n_1} \dots \left(\frac{v_K(\boldsymbol{\theta})}{N} \right)^{n_K}$$

$$\ln L(\boldsymbol{\theta}) = \sum_{i=1}^K n_i \ln[v_i(\boldsymbol{\theta})] + \ln \left(\frac{N!}{n_1! n_2! \dots n_K!} \right)$$

posteriorní hustota pravděpodobnosti: $f(\boldsymbol{\theta}|\mathbf{n}) \propto L(\boldsymbol{\theta})f(\boldsymbol{\theta})$




Příklad – difrakce na štěrbíně



$$I = I_0 \left(\frac{\sin u}{u} \right)^2 \quad u = \frac{1}{2} kb\phi \quad (-\phi_0, \phi_0)$$

Příklad – difrakce na šěrbině



$$I = I_0 \left(\frac{\sin u}{u} \right)^2 \quad u = \frac{1}{2} kb\phi \quad (-\phi_0, \phi_0)$$

• normalizace: $\frac{1}{\xi} = \int_{-\phi_0}^{\phi_0} I(\phi) d\phi \quad I = \xi(b) \left(\frac{\sin u(b)}{u(b)} \right)^2$


$$v_i(\boldsymbol{\theta}) = N \int_{\phi_i - \frac{\Delta}{2}}^{\phi_i + \frac{\Delta}{2}} \xi(b) \left(\frac{\sin\left(\frac{1}{2} kb\phi\right)}{\frac{1}{2} kb\phi} \right)^2 d\phi \approx N \xi(b) \left(\frac{\sin\left(\frac{1}{2} kb\phi\right)}{\frac{1}{2} kb\phi} \right)^2 \Delta$$

$$\ln L = \sum_{i=1}^K n_i \ln v_i(\boldsymbol{\theta}) = \sum_{i=1}^K n_i \ln(\xi(b)) + 2 \sum_{i=1}^K n_i \ln\left(\sin\left(\frac{1}{2} kb\phi_i\right)\right) - 2 \sum_{i=1}^K n_i \ln\left(\frac{1}{2} kb\phi_i\right) + \ln \Delta$$

$$\sigma_b \approx \left(- \frac{d^2 \ln L}{db^2} \Big|_{b=b_0} \right)^{-\frac{1}{2}}$$

Příklad – difrakce na štěrbíně

$$\ln L = \sum_{i=1}^K n_i \ln v_i(\boldsymbol{\theta}) = \sum_{i=1}^K n_i \ln(\xi(b)) + 2 \sum_{i=1}^K n_i \ln\left(\sin\left(\frac{1}{2}kb\varphi_i\right)\right) - 2 \sum_{i=1}^K n_i \ln\left(\frac{1}{2}kb\varphi_i\right) + \ln \Delta$$



Příklad – difrakce na štěrbině

$$\frac{n_i - I(\phi_i)}{\sqrt{n_i}}$$

