



Odhady parametrů (estimátory)

- sada naměřených hodnot $\mathbf{x} = (x_1, x_2, \dots, x_n)$ $x_i \in f(x|\boldsymbol{\theta})$ jsou nezávislé
 - parametry rozdělení $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$
 - odhad parametru (estimátor) $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m)$
 - Cíl: Najít nejlepší odhady $\hat{\theta}_j$ parametrů θ_j .
-



Vlastnosti odhadů (estimátorů)

- sada naměřených hodnot $\mathbf{x} = (x_1, x_2, \dots, x_n)$ $x_i \in f(x|\boldsymbol{\theta})$ jsou nezávislé
 - parametry rozdělení $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$
 - odhad parametru (estimátor) $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m)$
 - Cíl: Najít nejlepší odhady $\hat{\theta}_j$ parametrů θ_j .
-

1. konzistence

pro $n \rightarrow \infty$ konverguje $\hat{\theta}_j \rightarrow \theta_j$

2. předpojatost

$$b \equiv E[\hat{\theta}_j] - \theta_j$$

$b = 0 \Rightarrow$ nevychýlený (nepředpojatý) odhad

3. efektivita

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

statistická a systematická chyba odhadu

Metoda maximální věrohodnosti

- sada naměřených hodnot $\mathbf{x} = (x_1, x_2, \dots, x_n)$ $x_i \in f(x|\boldsymbol{\theta})$ jsou nezávislé
- parametry rozdělení $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$
- odhad parametru (estimátor) $\hat{\boldsymbol{\theta}} = (\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m)$
- Cíl: Najít nejlepší odhady $\hat{\theta}_j$ parametrů θ_j .

$$L(\boldsymbol{\theta}|\mathbf{x}) \equiv \prod_{i=1}^n f(x_i|\boldsymbol{\theta})$$

-
- pravděpodobnost $P(x \in (x_i, x_i + dx)) = f(x_i|\boldsymbol{\theta})dx$
 - pravděpodobnost, že naměříme hodnoty (x_1, x_2, \dots, x_n)

$$P = \prod_{i=1}^n f(x_i|\boldsymbol{\theta})dx$$

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

- hledáme hodnoty $\hat{\boldsymbol{\theta}}$, pro které $L(\hat{\boldsymbol{\theta}})$ nabývá maximum

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

Odhad parametrů normálního rozdělení

- sada naměřených hodnot

$$\mathbf{x} = (x_1, x_2, \dots, x_n)$$

- hustoty pravděpodobnosti

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

- věrohodnostní funkce

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

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

- odhad očekávané hodnoty

$$\left. \frac{\partial \ln L}{\partial \mu} \right|_{\mu=\hat{\mu}} = 0 \Rightarrow \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i$$

- odhad rozptylu

$$\left. \frac{\partial \ln L}{\partial \sigma} \right|_{\sigma=\hat{\sigma}} = 0 \Rightarrow \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$$

Musíme znát skutečnou očekávanou hodnotu!

Odhad parametrů normálního rozdělení

- věrohodný odhad očekávané hodnoty

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i \quad (\text{aritmetický průměr})$$

- věrohodný 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?

$$E[\hat{\mu}] = \frac{1}{n} \sum_{i=1}^n E[x_i] = \mu$$

⇒ nepředpojatý odhad

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

⇒ nepředpojatý odhad

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

⇒ předpojatý odhad

- nepředpojatý odhad rozptylu

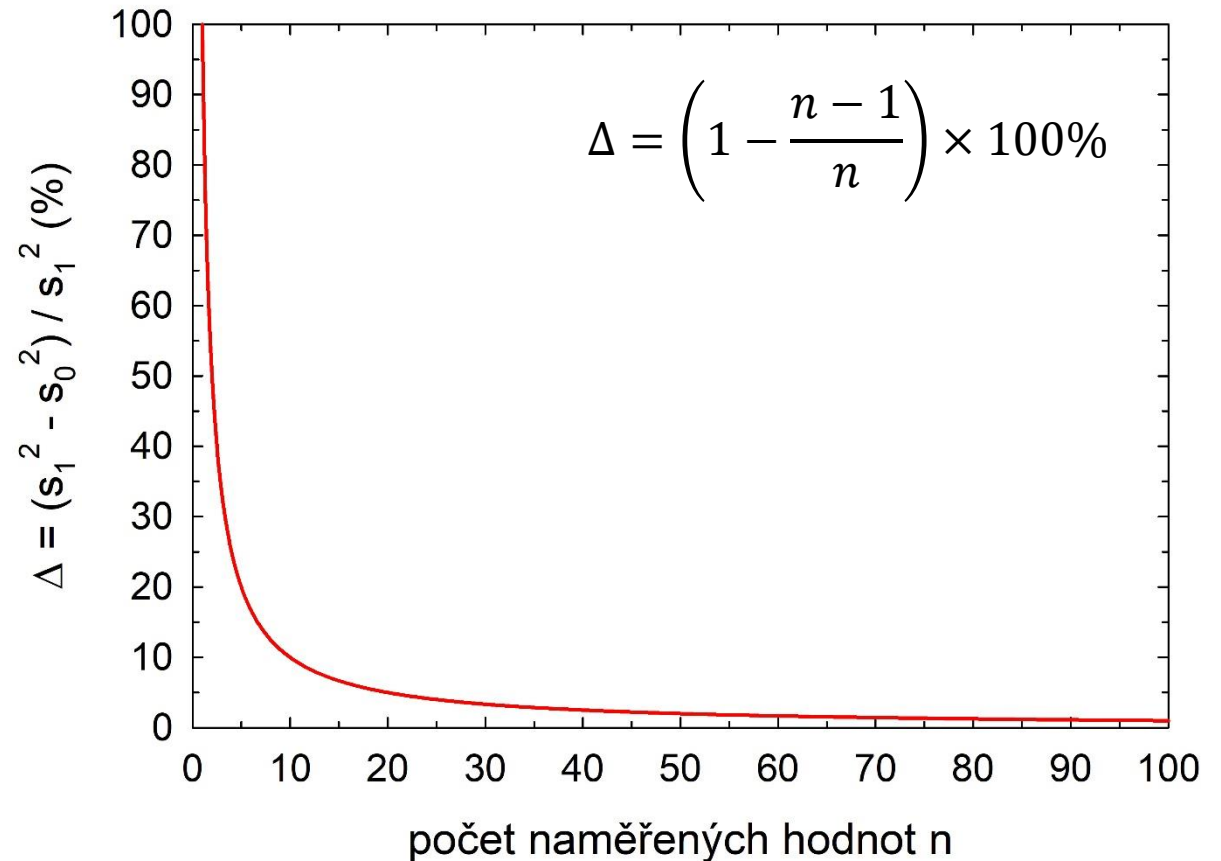
$$s_1^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

Odhad parametrů normálního rozdělení

$$s_0 = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$


$$s_1 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

$$\Delta = \frac{s_1^2 - s_0^2}{s_1^2} = 1 - \frac{n-1}{n} = \frac{1}{n}$$



Metoda nejmenších čtverců

- sada naměřených hodnot $\mathbf{x} = (x_1, x_2, \dots, x_n)$ (nezávislé proměnné)
 $\mathbf{y} = (y_1, y_2, \dots, y_n)$ (závislé proměnné) $y_i \in N(\mu_i, \sigma_i)$
- modelová funkce $\lambda(x|\boldsymbol{\theta})$ modelujeme závislost $y(x)$
 $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$ (parametry modelové závislosti)



Metoda nejmenších čtverců

- sada naměřených hodnot $\mathbf{x} = (x_1, x_2, \dots, x_n)$ (nezávislé proměnné)
 $\mathbf{y} = (y_1, y_2, \dots, y_n)$ (závislé proměnné) $y_i \in N(\mu_i, \sigma_i)$
- modelová funkce $\lambda(x|\boldsymbol{\theta})$ modelujeme závislost $y(x)$
 $\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m)$ (parametry modelové závislosti)

- věrohodnostní funkce
$$L(\boldsymbol{\theta}|\mathbf{y}, \boldsymbol{\sigma}, \mathbf{x}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_i^2}} \exp\left[-\frac{(y_i - \lambda(x_i|\boldsymbol{\theta}))^2}{2\sigma_i^2}\right]$$
$$\ln L(\boldsymbol{\theta}|\mathbf{y}, \boldsymbol{\sigma}, \mathbf{x}) = -\sum_{i=1}^n \frac{(y_i - \lambda(x_i|\boldsymbol{\theta}))^2}{2\sigma_i^2} - \sum_{i=1}^n \ln\left(\sqrt{2\pi\sigma_i^2}\right)$$

- minimalizujeme tzv. „chí kvadrát“

$$\chi^2(\boldsymbol{\theta}|\mathbf{y}, \boldsymbol{\sigma}, \mathbf{x}) = \sum_{i=1}^n \frac{(y_i - \lambda(x_i|\boldsymbol{\theta}))^2}{\sigma_i^2}$$

Metoda nejmenších čtverců – lineární fit

$$y = m \cdot x$$

- modelová funkce

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

- „chí kvadrát“

$$\chi^2(m|\mathbf{y}, \boldsymbol{\sigma}, \mathbf{x}) = \sum_{i=1}^n \frac{(y_i - m \cdot x_i)^2}{\sigma_i^2}$$

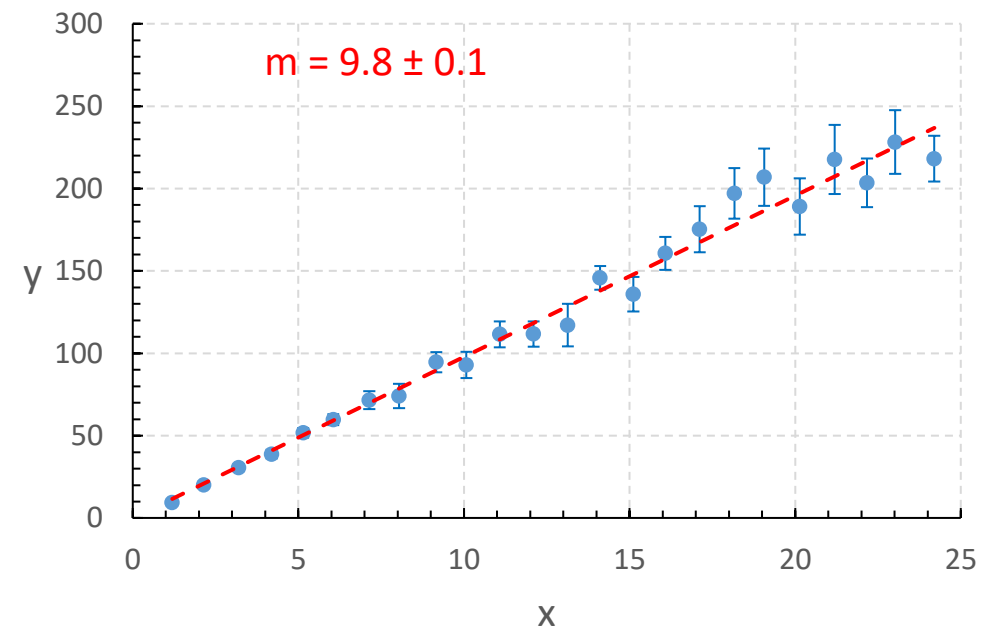
- lineární regrese

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

- přenos chyb

$$\sigma_{\hat{m}}^2 = \frac{1}{\sum_{i=1}^n \frac{x_i^2}{\sigma_i^2}} = \frac{1}{\langle x^2 \rangle}$$

Lineární regrese $y = m x$



- označení

$$\langle a \rangle \equiv \sum_{i=1}^n \frac{a_i}{\sigma_i^2} \quad (\text{vážený průměr})$$

Metoda nejmenších čtverců – lineární fit

$$y = a \cdot x + b$$

- modelová funkce

$$\lambda(x|a) = a \cdot x + b$$

- „chí kvadrát“

$$\chi^2(a, b | \mathbf{y}, \boldsymbol{\sigma}, \mathbf{x}) = \sum_{i=1}^n \frac{(y_i - a \cdot x_i - b)^2}{\sigma_i^2}$$

- lineární regrese

$$\hat{a} = \frac{\langle 1 \rangle \langle xy \rangle - \langle x \rangle \langle y \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

$$\sigma_{\hat{a}}^2 = \frac{\langle 1 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

$$\hat{b} = \frac{\langle y \rangle \langle x^2 \rangle - \langle x \rangle \langle xy \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

$$\sigma_{\hat{b}}^2 = \frac{\langle x^2 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

$$\text{cov}(\hat{a}, \hat{b}) = \frac{-\langle x \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

Lineární regrese $y = a x + b$

