

# MATEMATICKÁ STATISTIKA

**Dana Černá**

<http://www.fp.tul.cz/kmd/>

Katedra matematiky a didaktiky matematiky

Technická univerzita v Liberci

## Intervalový odhad

$(P_1, P_2) \subset (-\infty, \infty)$  se nazývá **intervalový odhad** parametru  $\theta$  se spolehlivostí  $1 - \alpha$ , jestliže  $P(\theta \in (P_1, P_2)) = 1 - \alpha$ .

Intervalový odhad tvaru  $(\hat{\theta} + P, \hat{\theta} - P)$ ,  $\hat{\theta}$ ,  $P \in \mathbb{R}$ , se nazývá **oboustranný intervalový odhad**.

Intervalový odhad tvaru  $(P_1, \infty)$ ,  $P_1 \in \mathbb{R}$ , se nazývá **dolní intervalový odhad**.

Intervalový odhad tvaru  $(-\infty, P_2)$ ,  $P_2 \in \mathbb{R}$ , se nazývá **horní intervalový odhad**.

## Intervalový odhad střední hodnoty náhodné veličiny s normálním rozdělením pravděpodobnosti

Předpokládejme, že  $X_1, \dots, X_n$  je náhodný výběr z rozdělení  $N(\mu, \sigma^2)$ , kde rozptyl  $\sigma^2 > 0$  známe. Potom  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  má rozdělení  $N(\mu, \sigma^2/n)$ .

Protože  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ , platí  $P\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < u\right) = \Phi(u)$ , kde  $\Phi$  je distribuční funkce rozdělení  $N(0, 1)$ .

Pro požadovanou spolehlivost  $1 - \alpha$  dostaneme

$P\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < u_{1-\alpha}\right) = 1 - \alpha$  kde  $u_{1-\alpha} := \Phi^{-1}(1 - \alpha)$  se nazývá  $1 - \alpha$  kvantil rozdělení  $N(0, 1)$ .

Po úpravě dostaneme  $P\left(\bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\alpha} < \mu\right) = 1 - \alpha$ .

Z toho plyne, že  $\left(\bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\alpha}, \infty\right)$  je dolní intervalový odhad parametru  $\mu$  o spolehlivosti  $1 - \alpha$ .

Podobně lze odvodit horní a oboustranný odhad střední hodnoty náhodné veličiny s normálním rozdělením pravděpodobnosti a známým rozptylem.

$\left(-\infty, \bar{X} + \frac{\sigma}{\sqrt{n}} u_{1-\alpha}\right)$  je horní intervalový odhad parametru  $\mu$ .

$\left(\bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}, \bar{X} + \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}\right)$  je oboustranný intervalový odhad parametru  $\mu$ .

## Regrese

**Model:**  $Y_i = f_\beta(x_i) + \epsilon_i$ ,  $i = 1, \dots, n$ ,

kde  $x_1, \dots, x_n \in \mathbb{R}$ ,  $Y_1, \dots, Y_n$  jsou náhodné veličiny,  $\epsilon_1, \dots, \epsilon_n$  jsou nezávislé náhodné veličiny reprezentující chybu modelu,  $E\epsilon_i = 0$ ,  $\text{var } \epsilon_i = \sigma^2 < \infty$ ,  $\beta = (\beta_0, \dots, \beta_k)$  je vektor parametrů.

**Cíl:** Pro daná data  $(x_i, y_i)$ ,  $i = 1, \dots, n$ , určit odhad  $\hat{\beta}$  parametru  $\beta$ . Víme, že  $\beta \in M$ .

Definujme **reziduální součet čtverců**  $S_\beta = \sum_{i=1}^n (y_i - f_\beta(x_i))^2$

Takové  $\hat{\beta}$ , pro které  $S_\beta$  nabývá minima na množině  $M$ , se nazývá **odhad parametru  $\beta$  metodou nejmenších čtverců**.

## Metody výpočtu $\hat{\beta}$ :

1. Minimalizujeme funkci  $S_{\beta}$ , tj. pomocí prvních derivací  $\frac{\partial S}{\partial \beta_i}$  určíme stacionární body  $S_{\beta}$  a pomocí druhých derivací rozhodneme, zda v nich  $S_{\beta}$  nabývá minima.
2. Je-li  $f_{\beta}$  lineární, řešíme soustavu lineárních algebraických rovnic  $y_i = f_{\beta}(x_i)$ ,  $i = 1, \dots, n$ , ve smyslu nejmenších čtverců.

## Příklady regresních modelů:

### 1. Lineární regrese

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, \dots, n$$

### 2. Polynomiální regrese

$$Y_i = \beta_0 + \beta_1 x_i + \dots + \beta_k x_i^k + \epsilon_i, \quad i = 1, \dots, n$$

### 3. Vícerozměrná lineární regrese

$$Y_i = \beta_1 x_{i1} + \beta_2 x_{i2} \dots + \beta_k x_{ik} + \epsilon_i, \quad i = 1, \dots, n$$

## 4. Nelineární model

je například model

$$Y_i = \beta_0 e^{\beta_1 x_i} + \epsilon_i, \quad i = 1, \dots, n.$$

Po zlogaritmování dostaneme

$$\ln Y_i \approx \ln \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n,$$

což lze zapsat jako lineární model

$$\tilde{Y}_i \approx \tilde{\beta}_0 + \beta_1 x_i, \quad i = 1, \dots, n, \quad \text{kde } \tilde{Y}_i = \ln Y_i, \quad \tilde{\beta}_0 = \ln \beta_0.$$

Nevýhodou je, že nyní náhodná veličina reprezentující chybu nesplňuje předpoklady.