

# A6M33SSL: Vzorke ke zkoušce

25. května 2016

## 1 Vlastnosti podmíněných rozdělení

$$\begin{aligned} EY &= E(E(Y|X)), \\ DY &= D(E(Y|X)) + E(D(Y|X)). \end{aligned}$$

## 2 Intervalové odhady parametrů **normálního** rozdělení $N(\mu, \sigma^2)$

(Uvedeny pouze symetrické oboustranné odhady.)

Odhad střední hodnoty při **známém** rozptylu  $\sigma^2$ :  $\bar{x} \pm \frac{\sigma}{\sqrt{n}} \Phi^{-1} \left(1 - \frac{\alpha}{2}\right)$ .

Odhad střední hodnoty při **neznámém** rozptylu:  $\bar{x} \pm \frac{\sigma}{\sqrt{n}} q_{t(n-1)} \left(1 - \frac{\alpha}{2}\right)$ .

Odhad rozptylu:  $\left\langle \frac{(n-1)s_x^2}{q_{\chi^2(n-1)} \left(1 - \frac{\alpha}{2}\right)}, \frac{(n-1)s_x^2}{q_{\chi^2(n-1)} \left(\frac{\alpha}{2}\right)} \right\rangle$ .

## 3 Testování hypotéz

**Typický tvar testu:** Testovací statistiku  $T$  (přesněji její realizaci  $t$ ), která roste s parametrem  $\theta$ , porovnáme s kvantily příslušného rozdělení za předpokladu  $\theta = c$ :

$H_0$	$H_A$	$H_0$ zamítáme, když	dosažená významnost $P$
$\theta \leq c$	$\theta > c$	$t > q_T(1 - \alpha)$	$1 - F_T(t)$
$\theta \geq c$	$\theta < c$	$t < q_T(\alpha)$	$F_T(t)$
$\theta = c$	$\theta \neq c$	$t > q_T(1 - \frac{\alpha}{2})$ nebo $t < q_T(\frac{\alpha}{2})$	$2 \min(F_T(t), 1 - F_T(t))$

Test střední hodnoty normálního rozdělení při **známém** rozptylu  $\sigma^2$ :  $\frac{\bar{x} - c}{\frac{\sigma}{\sqrt{n}}}$  testujeme na rozdělení  $N(0, 1)$ .

Test střední hodnoty normálního rozdělení při **neznámém** rozptylu:  $\frac{\bar{x} - c}{\frac{s_x}{\sqrt{n}}}$  testujeme na rozdělení  $t(n - 1)$ .

Test rozptylu normálního rozdělení:  $\frac{(n-1)s_x^2}{c}$  testujeme na rozdělení  $\chi^2(n - 1)$ .

Test rovnosti rozptylů dvou normálních rozdělení (Fisherův):  $\frac{s_x^2}{s_y^2}$  testujeme na rozdělení  $F(m - 1, n - 1)$ .

Test rovnosti středních hodnot dvou normálních rozdělení se **známým** rozptylem  $\sigma^2$ :  $\frac{\bar{x}_m - \bar{y}_n}{\sigma \sqrt{\frac{1}{m} + \frac{1}{n}}}$  testujeme na rozdělení  $N(0, 1)$ .

Test rovnosti středních hodnot dvou normálních rozdělení s **neznámým** rozptylem:  $\frac{\bar{x}_m - \bar{y}_n}{s \sqrt{\frac{1}{m} + \frac{1}{n}}}$ , kde

$s^2 = \frac{(m-1)s_x^2 + (n-1)s_y^2}{m+n-2}$ , testujeme na rozdělení  $t(m+n-2)$ .

**Párový pokus** - test rovnosti středních hodnot dvou normálních rozdělení se **známým** rozptylem  $\sigma^2$ :  $\frac{\bar{x} - \bar{y}}{\sigma} \sqrt{\frac{n}{2}}$  testujeme na rozdělení  $N(0, 1)$ .

**Párový pokus** - test rovnosti středních hodnot dvou normálních rozdělení se **neznámým** rozptylem:  $\frac{\bar{\delta}}{s_\delta} \sqrt{n}$ , kde  $\delta_j = x_j - y_j$ , testujeme na rozdělení  $t(n - 1)$ .

### 3.1 Testy korelace

$$r_{\mathbf{x}, \mathbf{y}} = \frac{\sum_{j=1}^n (x_j - \bar{x})(y_j - \bar{y})}{\sqrt{\left(\sum_{j=1}^n (x_j - \bar{x})^2\right) \left(\sum_{j=1}^n (y_j - \bar{y})^2\right)}} = \frac{n \sum_{j=1}^n x_j y_j - \left(\sum_{j=1}^n x_j\right) \left(\sum_{j=1}^n y_j\right)}{\sqrt{\left(n \sum_{j=1}^n x_j^2 - \left(\sum_{j=1}^n x_j\right)^2\right) \left(n \sum_{j=1}^n y_j^2 - \left(\sum_{j=1}^n y_j\right)^2\right)}} = \rho(\text{Emp}(\mathbf{x}, \mathbf{y})),$$

$$z_{\mathbf{x}, \mathbf{y}} = \frac{1}{2} \ln \frac{1 + r_{\mathbf{x}, \mathbf{y}}}{1 - r_{\mathbf{x}, \mathbf{y}}} = h(r_{\mathbf{x}, \mathbf{y}}), \text{ kde } h(t) = \frac{1}{2} \ln \frac{1+t}{1-t}.$$

Test nekorelovanosti dvou normál. rozdělení,  $H_0 : \rho(X, Y) = 0$ :  $\frac{r_{\mathbf{x}, \mathbf{y}}}{\sqrt{1 - r_{\mathbf{x}, \mathbf{y}}^2}} \sqrt{n-2}$  testujeme na rozdělení  $t(n-2)$ .

Test **nenulové** hodnoty korelace dvou normálních rozdělení,  $H_0 : \rho(X, Y) = c$ , kde  $c \neq 0$ :

$$(h(r_{\mathbf{x}, \mathbf{y}}) - h(c)) \sqrt{n-3} = \frac{z_{\mathbf{x}, \mathbf{y}} - \mu_{z_{\mathbf{x}, \mathbf{y}}}}{\sigma_{z_{\mathbf{x}, \mathbf{y}}}}, \text{ kde } \mu_{z_{\mathbf{x}, \mathbf{y}}} = h(c) = \frac{1}{2} \ln \frac{1+c}{1-c} \text{ a } \sigma_{r_{\mathbf{x}, \mathbf{y}}} = \sqrt{\frac{1}{n-3}}, \text{ testujeme na rozd. } N(0, 1).$$

Test rovnosti korelací dvou normálních rozdělení,  $H_0 : \rho(X, Y) = \rho(U, V)$ :  $\frac{h(r_{\mathbf{x}, \mathbf{y}}) - h(r_{\mathbf{u}, \mathbf{v}})}{\sqrt{\frac{1}{n-3} + \frac{1}{m-3}}} = \frac{z_{\mathbf{x}, \mathbf{y}} - z_{\mathbf{u}, \mathbf{v}}}{\sigma_Z}$ , kde

$$\sigma_Z = \sqrt{\frac{1}{n-3} + \frac{1}{m-3}}, \text{ testujeme na rozdělení } N(0, 1).$$

## 4 Regrese

### 4.1 Lineární model dimenze 1

$$Y = \theta_0 + \theta_1 X + \mathcal{E}, \quad y_j = \theta_0 + \theta_1 x_j + e_j.$$

Regresní přímka 1:

$$\begin{aligned} y &= \hat{\theta}_0 + \hat{\theta}_1 x, & y - \bar{y} &= \hat{\theta}_1 (x - \bar{x}), \\ \hat{\theta}_0 &= \bar{y} - \hat{\theta}_1 \bar{x}, & \hat{\theta}_1 &= \frac{\sum_j x_j y_j - n \bar{x} \bar{y}}{\sum_j x_j^2 - n \bar{x}^2} = \frac{\sum_j (x_j - \bar{x})(y_j - \bar{y})}{\sum_j (x_j - \bar{x})^2}. \end{aligned}$$

Odhad hodnot nezávisle proměnné v jednotlivých realizacích a chyby (**rezidua**):  $y_j = \hat{\theta}_0 + \hat{\theta}_1 x_j, \quad \hat{e}_j = y_j - \hat{y}_j.$

Regresní přímka 2:  $x = \hat{\theta}_0^* + \hat{\theta}_1^* y, \quad x - \bar{x} = \hat{\theta}_1^* (y - \bar{y}).$

### 4.2 Interpretace regresních koeficientů

$$\begin{aligned} \hat{\sigma}_{\mathbf{x}}^2 &= \frac{1}{n} \sum_j (x_j - \bar{x})^2 = \frac{n-1}{n} s_{\mathbf{x}}^2 = D \text{Emp}(\mathbf{x}), \\ \hat{\sigma}_{\mathbf{y}}^2 &= \frac{1}{n} \sum_j (y_j - \bar{y})^2 = \frac{n-1}{n} s_{\mathbf{y}}^2 = D \text{Emp}(\mathbf{y}), \\ c_{\mathbf{x}, \mathbf{y}} &= \frac{1}{n} \sum_j (x_j - \bar{x})(y_j - \bar{y}) = \text{cov}(\text{Emp}(\mathbf{x}, \mathbf{y})), \\ r_{\mathbf{x}, \mathbf{y}} &= \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_{\mathbf{x}} \hat{\sigma}_{\mathbf{y}}} = \rho(\text{Emp}(\mathbf{x}, \mathbf{y})), \quad \hat{\theta}_1 = \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_{\mathbf{x}}^2}, \quad \hat{\theta}_1 \hat{\theta}_1^* = r_{\mathbf{x}, \mathbf{y}}^2. \end{aligned}$$

Regresní přímka 1:  $y - \bar{y} = \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_{\mathbf{x}}^2} (x - \bar{x}), \quad \frac{y - \bar{y}}{\hat{\sigma}_{\mathbf{y}}} = r_{\mathbf{x}, \mathbf{y}} \frac{x - \bar{x}}{\hat{\sigma}_{\mathbf{x}}}.$

### 4.3 Složky rozptylu regresního odhadu

**Rozptyl modelu (vysvětlený rozptyl):**  $\hat{\sigma}_{\hat{\mathbf{y}}}^2 = \frac{1}{n} \sum_j (\hat{y}_j - \bar{y})^2$ .

**Reziduální rozptyl (nevysvětlený rozptyl):**  $\hat{\sigma}_{\hat{\mathbf{e}}}^2 = \frac{1}{n} \sum_j \hat{e}_j^2 = \frac{1}{n} \sum_j (y_j - \hat{y}_j)^2$ .

**Celkový rozptyl:**  $\hat{\sigma}_{\mathbf{y}}^2 = \frac{1}{n} \sum_j (y_j - \bar{y})^2 = \hat{\sigma}_{\hat{\mathbf{y}}}^2 + \hat{\sigma}_{\hat{\mathbf{e}}}^2$ . **Koeficient determinace:**  $r_{\mathbf{x}, \mathbf{y}}^2 = \frac{\hat{\sigma}_{\hat{\mathbf{y}}}^2}{\hat{\sigma}_{\mathbf{y}}^2} = 1 - \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{\hat{\sigma}_{\mathbf{y}}^2}$ .

Odhady rozptylu  $\sigma^2$  původního rozdělení:

- max. věrohodný:  $\hat{\sigma}_{\hat{\mathbf{e}}}^2 = \frac{1}{n} \sum_j \hat{e}_j^2 = \text{D Emp}(\hat{\mathbf{e}})$ ,

- nestranný:  $\hat{\sigma}^2 = \frac{1}{n-2} \sum_j \hat{e}_j^2$ .

### 4.4 Rozdělení odhadů a testy hypotéz o nich

Odhady rozptylů regresních koeficientů:

$$\hat{\sigma}_{\hat{\theta}_0}^2 = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{n^2 \hat{\sigma}_{\mathbf{x}}^2} \sum_j x_j^2 = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{n(n-2) \hat{\sigma}_{\mathbf{x}}^2} \sum_j x_j^2, \quad \hat{\sigma}_{\hat{\theta}_1}^2 = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{n \hat{\sigma}_{\mathbf{x}}^2} = \frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{(n-2) \hat{\sigma}_{\mathbf{x}}^2}.$$

Test absolutního členu,  $H_0 : \theta_0 = c$ :  $\frac{\hat{\theta}_0 - c}{\frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{\hat{\sigma}_{\mathbf{x}}^2} \sqrt{\frac{1}{n} \sum_j x_j^2}} \sqrt{n-2}$  testujeme na rozdělení  $t(n-2)$ .

Test směrnice,  $H_0 : \theta_1 = c$ :  $\frac{\hat{\theta}_1 - c}{\frac{\hat{\sigma}_{\hat{\mathbf{e}}}^2}{\hat{\sigma}_{\mathbf{x}}^2}} \sqrt{n-2}$  testujeme na rozdělení  $t(n-2)$ .

Test chyby regrese pro dané  $x$ ,  $H_0 : \theta_0 + \theta_1 x = c$ :  $\frac{\hat{\theta}_0 + \hat{\theta}_1 x - c}{\hat{\sigma}_{\hat{\mathbf{e}}} \sqrt{n+1 + \frac{n(x-\bar{x})^2}{\hat{\sigma}_{\mathbf{x}}^2}}} \sqrt{n-2}$  testujeme na rozdělení  $t(n-2)$ .

### 4.5 Lineární model dimenze $k$

$$Y = \sum_{i=1}^k \theta_i X_i + \mathcal{E}, \quad y_j = \sum_{i=1}^k \theta_i x_{ji} + e_j, \quad \mathbf{y} = \mathbf{X}\boldsymbol{\theta} + \mathbf{e}.$$

Soustava normálních rovnic a její řešení:  $\mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\theta}} = \mathbf{X}^T \mathbf{y}$ ,  $\hat{\boldsymbol{\theta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$ .

Kovarianční matice vektoru odhadů  $\hat{\boldsymbol{\theta}}$ :  $\boldsymbol{\Sigma}_{\hat{\boldsymbol{\theta}}} = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}$ .

**Reziduální součet čtverců:**  $R_{SS} = \sum_{j=1}^n \hat{e}_j^2$ .

$\frac{R_{SS}}{\sigma^2}$  pochází z rozdělení  $\chi^2(n-k)$ .

Odhady rozptylu  $\sigma^2$  původního rozdělení:

- maximálně věrohodný:  $\hat{\sigma}_{\hat{\mathbf{e}}}^2 = \frac{1}{n} R_{SS} = \frac{1}{n} \sum_{j=1}^n \hat{e}_j^2$ ,

- nestranný:  $\hat{\sigma}^2 = \frac{1}{n-k} R_{SS} = \frac{1}{n-k} \sum_{j=1}^n \hat{e}_j^2$ .

### 4.6 Intervalové odhady regresních koeficientů

$c_{ii}$  je  $i$ -tý prvek na diagonále matice  $\mathbf{C} = (\mathbf{X}^T \mathbf{X})^{-1}$ .

Intervalový odhad regresních koeficientů při **známém** rozptylu  $\sigma^2$ :  $\hat{\theta}_i \pm \Phi^{-1} \left(1 - \frac{\alpha}{2}\right) \sigma \sqrt{c_{ii}}$ .

Intervalový odhad regresních koeficientů při **neznámém** rozptylu:

$$\hat{\theta}_i \pm q_{t(n-k)} \left(1 - \frac{\alpha}{2}\right) \hat{\sigma} \sqrt{c_{ii}} = \hat{\theta}_i \pm q_{t(n-k)} \left(1 - \frac{\alpha}{2}\right) \sqrt{\frac{R_{SS} c_{ii}}{n-k}}.$$

## 5 $\chi^2$ testy

Test dobré shody pozorovaného rozdělení s diskretním rozdělením se **známými** parametry:  $\sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i}$  testujeme na rozdělení  $\chi^2(k-1)$ .

Test dobré shody pozorovaného rozdělení s diskretním rozdělením závislém na **neznámých** parametrech:

$\sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i}$  testujeme na rozdělení  $\chi^2(k-1-q)$ , kde  $q$  je počet parametrů rozdělení odhadnutých na základě téhož náhodného výběru.

Test dobré shody 2 diskretních rozdělení:  $\left(\frac{1}{m} + \frac{1}{n}\right) \sum_{i=1}^k \frac{(m_i - mp_i)^2}{p_i}$ , kde  $p_i = \frac{m_i + n_i}{m+n}$ , testujeme na rozdělení  $\chi^2(k-1)$ .

Test nezávislosti 2 diskretních rozdělení:  $\sum_{i=1}^k \sum_{j=1}^m \frac{(n_{ij} - np_i q_j)^2}{np_i q_j}$ , kde  $p_i = \frac{1}{n} \sum_{j=1}^m n_{ij}$  a  $q_j = \frac{1}{n} \sum_{i=1}^k n_{ij}$ , testujeme na rozdělení  $\chi^2((k-1)(m-1))$ .