

Statistika a spolehlivost v lékařství – vzorce ke zkoušce

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 σ^2 : $\bar{x} \pm \frac{\sigma}{\sqrt{n}} \Phi^{-1}\left(1 - \frac{\alpha}{2}\right)$.

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

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 , která roste s parametrem ϑ (přesněji její realizaci t) porovnáme s kvantily příslušného rozdělení za předpokladu $\vartheta = c$:

H_0	H_1	zamítáme pro	dosažená významnost
$\vartheta \leq c$	$\vartheta > c$	$t > q_T(1 - \alpha)$	$1 - F_T(t)$
$\vartheta \geq c$	$\vartheta < c$	$t < q_T(\alpha)$	$F_T(t)$
$\vartheta = c$	$\vartheta \neq c$	$t > q_T(1 - \frac{\alpha}{2})$ nebo $t < q_T(\frac{\alpha}{2})$	$2 \min(F_T(t), 1 - F_T(t))$

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

Test střední hodnoty normálního rozdělení při **neznámém** rozptylu: $\frac{\bar{x} - c}{s_x} \sqrt{n}$ 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 σ^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 se stejným **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 σ^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 stejným **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

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

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

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

Test (nenulové) hodnoty korelace dvou normálních rozdělení, $H_0: \varrho(X, Y) = c$, kde $c \neq 0$: $(h(r_{\mathbf{x}, \mathbf{y}}) - h(c)) \sqrt{n - 3} = \frac{z_{\mathbf{x}, \mathbf{y}} - \mu_{z_{\mathbf{x}, \mathbf{y}}}}{\sigma_{z_{\mathbf{x}, \mathbf{y}}}}$, kde $\mu_{z_{\mathbf{x}, \mathbf{y}}} = h(c) = \frac{1}{2} \ln \frac{1 + c}{1 - c}$, $\sigma_{z_{\mathbf{x}, \mathbf{y}}} = \sqrt{\frac{1}{n - 3}}$, testujeme na rozdělení $N(0, 1)$.

Test rovnosti korelací dvou normálních rozdělení, $H_0: \varrho(X, Y) = \varrho(U, V)$: $\frac{h(r_{\mathbf{x}, \mathbf{y}}) - h(r_{\mathbf{u}, \mathbf{v}})}{\sqrt{\frac{1}{n-3} + \frac{1}{m-3}}} = \frac{z_{\mathbf{x}, \mathbf{y}} - z_{\mathbf{u}, \mathbf{v}}}{\sigma_Z}$, kde $\sigma_Z = \sqrt{\frac{1}{n-3} + \frac{1}{m-3}}$, testujeme na rozdělení $N(0, 1)$.

4 Regrese

4.1 Lineární model dimenze 1

$$Y = \vartheta_0 + \vartheta_1 X + \mathcal{E} , \quad y_j = \vartheta_0 + \vartheta_1 x_j + e_j .$$

Regresní přímka 1:

$$y = \hat{\vartheta}_0 + \hat{\vartheta}_1 x , \quad \hat{\vartheta}_0 = \bar{y} - \hat{\vartheta}_1 \bar{x} , \quad \hat{\vartheta}_1 = \frac{y - \bar{y} = \hat{\vartheta}_1 (x - \bar{x})}{\sum_j x_j y_j - n \bar{x} \bar{y}} = \frac{\sum_j (x_j - \bar{x})(y_j - \bar{y})}{\sum_j (x_j - \bar{x})^2} .$$

Odhad hodnot nezávisle proměnné v jednotlivých realizacích a chyby (**rezidua**): $\hat{y}_j = \hat{\vartheta}_0 + \hat{\vartheta}_1 x_j$, $\hat{e}_j = y_j - \hat{y}_j$.
Regresní přímka 2: $x = \hat{\vartheta}_0^* + \hat{\vartheta}_1^* y$, $x - \bar{x} = \hat{\vartheta}_1^* (y - \bar{y})$.

4.2 Interpretace regresních koeficientů

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

$$r_{\mathbf{x}, \mathbf{y}} = \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_{\mathbf{x}} \hat{\sigma}_{\mathbf{y}}} , \quad \hat{\vartheta}_1 = \frac{c_{\mathbf{x}, \mathbf{y}}}{\hat{\sigma}_{\mathbf{x}}^2} , \quad \hat{\vartheta}_1 \hat{\vartheta}_1^* = r_{\mathbf{x}, \mathbf{y}}^2 .$$

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

4.3 Složky rozptylu regresního odhadu

$$\text{Rozptyl modelu} = \hat{\sigma}_{\hat{\boldsymbol{y}}}^2 = \frac{1}{n} \sum_j (\hat{y}_j - \bar{y})^2.$$

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

$$\text{Celkový rozptyl} = \hat{\sigma}_{\boldsymbol{y}}^2 = \frac{1}{n} \sum_j (y_j - \bar{y})^2 = \hat{\sigma}_{\hat{\boldsymbol{y}}}^2 + \hat{\sigma}_{\hat{\boldsymbol{e}}}^2. \quad r_{\boldsymbol{x}, \boldsymbol{y}}^2 = \frac{\hat{\sigma}_{\hat{\boldsymbol{y}}}^2}{\hat{\sigma}_{\boldsymbol{y}}^2} = 1 - \frac{\hat{\sigma}_{\hat{\boldsymbol{e}}}^2}{\hat{\sigma}_{\boldsymbol{y}}^2}.$$

Odhady rozptylu σ^2 původního rozdělení:

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

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

4.4 Rozdělení odhadů a testy hypotéz o nich

Odhady rozptylů regresních koeficientů:

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

Test absolutního členu, $H_0: \vartheta_0 = c$: $\frac{\hat{\vartheta}_0 - c}{\frac{\hat{\sigma}_{\hat{\boldsymbol{e}}}}{\hat{\sigma}_{\boldsymbol{x}}} \sqrt{\frac{1}{n} \sum_j x_j^2}} \sqrt{n-2}$ testujeme na rozdělení $t(n-2)$.

Test směrnice, $H_0: \vartheta_1 = c$: $\frac{\hat{\vartheta}_1 - c}{\frac{\hat{\sigma}_{\hat{\boldsymbol{e}}}}{\hat{\sigma}_{\boldsymbol{x}}} \sqrt{n-2}}$ testujeme na rozdělení $t(n-2)$.

Test chyby regrese pro dané x , $H_0: \vartheta_0 + \vartheta_1 x = c$: $\frac{\hat{\vartheta}_0 + \hat{\vartheta}_1 x - c}{\hat{\sigma}_{\hat{\boldsymbol{e}}} \sqrt{n+1 + \frac{n(x-\bar{x})^2}{\hat{\sigma}_{\boldsymbol{x}}^2}}} \sqrt{n-2}$ testujeme na rozdělení $t(n-2)$.

4.5 Lineární model dimenze k

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

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

Kovarianční matice vektoru odhadů $\hat{\boldsymbol{\Theta}}$: $\Sigma_{\hat{\boldsymbol{\Theta}}} = \sigma^2 (\boldsymbol{X}^T \boldsymbol{X})^{-1}$.

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 σ^2 původního rozdělení:

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

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

4.6 Intervalové odhady regresních koeficientů

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

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

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

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