

## Poznámky k předmětu Aplikovaná statistika, 12. téma

### Lineární regrese

Z teorie často víme, že naměřená data vykazují funkcionální závislost, ovšem zatíženou chybou měření. V našem případě je tato závislost lineární. Chtěli bychom najít takovou přímku, která „nejlépe“ (v jakém smyslu?) vystihuje naše data měřená s náhodnou chybou. Tuto úlohu lze popsat pomocí tzv. **lineární regrese**

$$Y(x) = \beta_1 + \beta_2 x + \epsilon(x),$$

kde

- pro každé  $x$  (nenáhodné!) z podmnožiny  $M$  reálných čísel je  $Y(x)$  náhodná veličina,
- $\beta_1, \beta_2 \in \mathbb{R}$  jsou parametry,
- pro každé  $x \in M$  je  $\epsilon(x)$  náhodná veličina (chyba měření).

Ona funkcionální závislost se nazývá **regresní funkce**  $\eta(x)$  a v lineárním případě je definovaná vztahem

$$\eta(x) = \mathbb{E}[Y(x)] = \beta_1 + \beta_2 x.$$

Sestavme tzv. **lineární regresní model**:

$$Y_j = \beta_1 + \beta_2 x_j + \epsilon_j, \quad j = 1, \dots, n,$$

kde pro hodnoty nezávislé proměnné  $x_j, j = 1, \dots, n$ , jsme označili

$$Y_j \equiv Y(x_j), \quad \epsilon_j \equiv \epsilon(x_j), \quad \eta(x_j) \equiv \eta_j, \quad j = 1, \dots, n.$$

Jeho **předpoklady** jsou

- $n > 2$  a existují  $i, j \in \{1, \dots, n\}$  taková, že  $x_i \neq x_j$ ,
- $\mathbb{E}Y_j = \eta_j = \beta_1 + \beta_2 x_j, \quad j = 1, \dots, n$ ,
- $\text{var} Y_j = \sigma^2 > 0, \quad j = 1, \dots, n$ ,
- $\text{cov}(Y_i, Y_j) = 0, \quad i, j = 1, \dots, n, i \neq j$ .

**Poznámka 1.** Podmínky (ii)–(iv) lze přepsat v řeči chyb  $\epsilon(x_j)$  následovně:

$$\mathbb{E} \epsilon_j = 0, \text{var} \epsilon_j = \sigma^2, \quad j = 1, \dots, n, \quad \text{cov}(\epsilon_i, \epsilon_j) = 0, \quad i, j = 1, \dots, n, i \neq j.$$

### Bodové odhady parametrů modelu

Model má tři parametry  $\beta_1, \beta_2, \sigma^2$ , pro něž bychom chtěli nalézt bodové odhady

$$\hat{\beta}_1 = b_1, \quad \hat{\beta}_2 = b_2, \quad \hat{\sigma}^2 = s^2.$$

- Pro odhady  $\beta_1, \beta_2$  se standardně používá **metoda nejmenších čtverců** – hledáme  $b_1, b_2$  tak, aby platilo

$$\sum_{j=1}^n (Y_j - (b_1 + b_2 x_j))^2 = \min_{\beta_1, \beta_2 \in M} \sum_{j=1}^n (Y_j - (\beta_1 + \beta_2 x_j))^2.$$

Je to aplikační úloha na lokální extrémy funkcí dvou proměnných (viz Matematiku II) a nalezená řešení  $b_1, b_2$  jsou nejlepšími nestrannými lineárními odhady parametrů  $\beta_1, \beta_2$ .

**Poznámka 2.** Bud'  $X_1, \dots, X_n$  náhodný výběr z rozdělení náhodné veličiny  $X$ . Bodový odhad  $\hat{\theta}_N \equiv \hat{\theta}_N(X_1, \dots, X_n)$  parametru  $\theta$  tohoto rozdělení je **nestranný**, jestliže

$$\mathbb{E} \hat{\theta}_N = \theta.$$

Nestranný bodový odhad  $\hat{\theta}_{NN}$  parametru  $\theta$  je **nejlepší nestranný odhad**, jestliže

$$\text{var } \hat{\theta}_{NN} = \min_{\hat{\theta}_N} \text{var } \hat{\theta}_N.$$

Bodový odhad  $\hat{\theta}$  je **lineární**, pokud existují konstanty  $a_0, a_1, \dots, a_n \in \mathbb{R}$  tak, že

$$\hat{\theta} = a_0 + \sum_{i=1}^n a_i X_i.$$

Ona řešení  $\beta_1, \beta_2$  lze vyjádřit ve tvaru

$$b_1 = \bar{Y} - b_2 \bar{x}, \tag{1}$$

$$b_2 = \frac{n \sum_{i=1}^n x_i Y_i - \sum_{i=1}^n x_i \sum_{i=1}^n Y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}, \tag{2}$$

kde

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i.$$

- Tudíž bodovým odhadem regresní funkce  $\eta_j$  je

$$\hat{\eta}_j = b_1 + b_2 x_j, \quad j = 1, \dots, n.$$

- Bodové odhady chyb  $\hat{\epsilon}_j$ ,  $j = 1, \dots, n$ , získané na základě metody nejmenších čtverců

$$\hat{\epsilon}_j = Y_j - b_1 - b_2 x_j$$

se nazývají **rezidua** a součet jejich kvadrátů (značí se  $S_e$ )

$$S_e = \sum_{j=1}^n \hat{\epsilon}_j^2 = \sum_{j=1}^n (Y_j - \hat{\eta}_j)^2 = \sum_{j=1}^n (Y_j - b_1 - b_2 x_j)^2$$

pak **reziduální součet čtverců**. Snadnou úpravou lze získat tvar vhodný pro výpočty

$$S_e = \sum_{j=1}^n Y_j^2 - b_1 \sum_{j=1}^n Y_j - b_2 \sum_{j=1}^n x_j Y_j.$$

Využitím reziduálního součtu čtverců obdržíme nestranný odhad rozptylu

$$s^2 = \hat{\sigma}^2 = \frac{1}{n-2} S_e,$$

který se nazývá **reziduální rozptyl**.

### Intervaly spolehlivosti – pás spolehlivosti a predikční pás

Pokud bychom chtěli konstruovat intervaly spolehlivosti pro parametry regresního modelu, potřebujeme dodatečné předpoklady na chyby:

- (i)  $\epsilon_j$ ,  $j = 1, \dots, n$ , jsou vzájemně nezávislé náhodné veličiny,
- (ii)  $\epsilon_j$ ,  $j = 1, \dots, n$  mají normální rozdělení  $\mathcal{N}(0, \sigma^2)$ .

Pak  $(1 - \alpha)100\%$  oboustranný interval spolehlivosti pro

- $\beta_1$  je

$$[b_1 - t_{1-\frac{\alpha}{2}}(n-2)s_{b_1}, b_1 + t_{1-\frac{\alpha}{2}}(n-2)s_{b_1}],$$

- $\beta_2$  je

$$[b_2 - t_{1-\frac{\alpha}{2}}(n-2)s_{b_2}, b_2 + t_{1-\frac{\alpha}{2}}(n-2)s_{b_2}], \quad (3)$$

- regresní funkci  $\eta(x)$  je

$$[b_1 + b_2x - t_{1-\frac{\alpha}{2}}(n-2)s_{\hat{\eta}(x)}, b_1 + b_2x + t_{1-\frac{\alpha}{2}}(n-2)s_{\hat{\eta}(x)}],$$

kde

$$s_{b_1}^2 = s^2 \frac{\sum_{i=1}^n x_i^2}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2},$$

$$s_{b_2}^2 = s^2 \frac{n}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2},$$

$$s_{\hat{\eta}(x)}^2 = s^2 \left( \frac{1}{n} + \frac{(x - \bar{x})^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right),$$

a  $t_{1-\frac{\alpha}{2}}(n-2)$  je  $(1 - \frac{\alpha}{2}) 100\%$  kvantil  $t$ -rozdělení s  $n-2$  stupni volnosti.

**Poznámka 3.** (a) *Vzhledem k nápadné podobnosti těchto intervalů spolehlivosti s intervaly spolehlivosti pro střední hodnotu (při neznámém rozptylu) též založených na  $t$ -rozdělení (s  $n-1$  stupni volnosti), si zkuste napsat jednostranné intervaly spolehlivosti pro parametry regresní funkce.*

(b) *Pomocí intervalů spolehlivosti lze testovat nulovost parametrů regresní funkce. Jak testovat hypotézy pomocí intervalů spolehlivosti jsme se naučili v tématu o jednovýběrových testech.*

Jestliže se díváme na horní a dolní meze intervalu spolehlivosti pro regresní funkci jako na funkce proměnné  $x$ , pak plocha ohraničená grafy těchto funkcí se nazývá **pás spolehlivosti kolem regresní přímky**. Obdobně lze zkonstruovat tzv. **predikční pás kolem regresní přímky**, což

je plocha ohraničená mezemi  $(1 - \alpha)100\%$  intervalů zkonstruovaných přímo pro náhodnou veličinu  $Y(x)$

$$\left[ b_1 + b_2x - t_{1-\frac{\alpha}{2}}(n-2)s_{\hat{Y}(x)}, b_1 + b_2x + t_{1-\frac{\alpha}{2}}(n-2)s_{\hat{Y}(x)} \right],$$

kde

$$s_{\hat{Y}(x)}^2 = s^2 \left( 1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \right) = s^2 + s_{\hat{\eta}(x)}^2.$$

Kvalitu modelu, tj. jak dobře lineární regresní model vystihuje naše data, lze posoudit např. pomocí tzv. **koeficientu determinace**

$$R^2 = 1 - \frac{S_e}{S_t},$$

kde  $S_e$  je výše definovaný reziduální součet čtverců a  $S_t$  je tzv. **celkový součet čtverců**

$$S_t = \sum_{j=1}^n (Y_j - \bar{Y})^2.$$

Koeficient determinace udává, jakou část celkové variability závisle proměnné  $Y$  se podařilo regresním modelem vysvětlit. Nabývá hodnot z intervalu  $[0, 1]$  a čím je blíže k jedné, tím lépe model naše data vystihuje.

**Příklad:** Experimentálně byla zjišťována závislost koncentrace nasyceného roztoku hydroxidu vápenatého  $Y$  (v %) na teplotě  $x$  (ve °C)

$x_j$	20	30	40	50	60	70	80
$y_j$	16,1	16,2	14,0	13,3	11,9	10,2	10,1

- Odhadněte bodově parametry lineární regrese a regresní funkci.
- Určete 95% intervaly spolehlivosti pro parametry regrese.
- Určete 95% interval spolehlivosti pro střední hodnotu koncentrace při teplotě 40 °C.
- Odhadněte bodově koncentraci nasyceného roztoku při teplotě 25 °C.