

NMAI059 Pravděpodobnost a statistika 1

11. přednáška

Robert Šámal

Přehled

Testy dobré shody

Lineární regrese

Bayesovská statistika

χ^2_k – rozdělení χ -kvadrát

$$z_i : \Omega \rightarrow \mathbb{R}$$


Definice

$Z_1, \dots, Z_k \sim N(0, 1)$ n.n.v. Rozdělení náhodné veličiny

$$\text{var } z_i = E z_i^2 - (E z_i)^2 = E z_i^2 \quad Q = Z_1^2 + \dots + Z_k^2 : \Omega \rightarrow \mathbb{R}$$

se nazývá χ -kvadrát s k stupni volnosti. (Opravdu k !)

- ▶ $E(Q) = k$ (lehké) $EQ = E \sum_i^k z_i^2 = \sum_i^k E z_i^2 = \sum_i^k 1 = k$
- ▶ $var(Q) = 2k$ (pro info, netřeba pamatovat) $EQ^2 = E(\sum_i^k z_i^2)(\sum_j^k z_j^2) = E \sum_{i,j} z_i^2 z_j^2 = \sum_{i,j} E z_i^2 z_j^2 = \sum_{i,j} 1 \cdot E z_i^2 \cdot E z_j^2 = 1 \cdot 1 = 1$
- ▶ hustota jde napsat vzorcem, jde najít např. na Wikipedii
- ▶ Q je pro velké n blízké $N(k, 2k)$ (CLV)



Multinomické a kategoriální rozdělení

Definice

Dána $p_1, \dots, p_k \geq 0$ tak, že $p_1 + p_2 + \dots + p_k = 1$.

n -krát zopakuji pokus, kde může nastat jedna z k možností, i -tá má pravděpodobnost p_i .

$X_i :=$ kolikát nastala i -tá možnost (X_1, \dots, X_k) má multinomické rozdělení s parametry $n, (p_1, \dots, p_k)$.

$$n = \sum_{i=1}^k X_i$$
$$0 \leq X_i \leq n$$

- triviální případ: $X_i =$ počet hodů kostkou, kdy padlo i
- důležitý případ: $X_i =$ počet výskytů i -tého písmene, i -tého slovního druhu, ...

$$P(X_1 = x_1, \dots, X_k = x_k) = \underbrace{\binom{n}{x_1, \dots, x_k}}_{\text{multinom. koef.}} p_1^{x_1} \cdots p_k^{x_k}$$

distribuční funkce rozděl.
 $\alpha_i = (p_1, p_2, p_3, \dots, p_k)$

$$\frac{n!}{x_1! \cdots x_k!} = \# \text{ uspoř. } \frac{x_1 \times \cdots \times x_k}{x_1! \cdots x_k!} \text{ do řady}$$

kategorie

$\rightarrow X_i \sim B(n, p_i)$
 \rightarrow složením 1 až n do řady

Poz kontrole

$$\sum_{x_1, \dots, x_k} P(X_1 = x_1, \dots, X_k = x_k) = \sum_{x_1, \dots, x_k} \binom{n}{x_1, \dots, x_k} p_1^{x_1} \cdots p_k^{x_k} =$$

$$\therefore 0 \leq x_1, \dots, x_k \leq n \quad \sum_{i=1}^k x_i = n$$

Pearsonova χ^2 statistika

- (X_1, \dots, X_k) – multinomické rozdělení s parametry n (p_1, \dots, p_k) jako minule
- $E_i := \mathbb{E}(X_i) = np_i$
- Pearsonova χ^2 statistika je funkce

$$\begin{aligned}\mu &= \mathbb{E} X_i \\ \sigma^2 &= \text{Var } X_i = np(1-p)\end{aligned}$$

$$\chi^2 = T := \sum_{i=1}^k \frac{(X_i - E_i)^2}{E_i}$$

$$T \xrightarrow{d} Z_i^2 \quad Z_i \sim N(0, 1)$$

► Věta $T \xrightarrow{d} \chi^2_{k-1}$

$$\Leftrightarrow \frac{(X_1 - np_1)^2}{np_1 p_2} (p_1, p_2)$$

$$T = \left(\frac{X_1 - np_1}{\sqrt{np_1(1-p_1)}} \right)^2$$

$$\begin{array}{|c|} \hline k=2 \\ \hline \end{array}$$

$$\begin{aligned}T &= \frac{(X_1 - E_1)^2}{E_1} + \frac{(X_2 - E_2)^2}{E_2} \\ &= \frac{(X_1 - np_1)^2}{np_1} + \frac{(n - X_1 - n(1-p_1))^2}{np_2} = \frac{(X_1 - np_1)^2}{np_1 p_2} + \frac{(X_2 - np_2)^2}{np_2 p_1} = \chi^2\end{aligned}$$

$$\frac{X_i - E_i}{\sigma} \xrightarrow{n \rightarrow \infty} N(0, 1) \quad [CLV]$$

Test dobré shody (goodness of fit)

- (X_1, \dots, X_k) – multinomické rozdělení s parametry $n, \vartheta = (\vartheta_1, \dots, \vartheta_k)$ jako minule
- n známe, ϑ neznáme.
- Hypotéza $H_0: \vartheta = \vartheta^*$



- $E_i := n\vartheta_i^*$ pro všechna i
- Použijeme statistiku $T := \sum_{i=1}^k \frac{(X_i - E_i)^2}{E_i}$
- Hypotézu H_0 zamítneme, pokud $T > \gamma$
- $\gamma := F_Q^{-1}(1 - \alpha)$, kde $Q \sim \chi_{k-1}^2$
- $P(\text{chyba prvního druhu}) = P(T > \gamma; H_0) \rightarrow P(Q > \gamma) = \alpha$

Test dobré shody – příklad (600x)

- ▶ Házíme opakovaně kostkou. Jednotlivá čísla padla s četností 92, 120, 88, 98, 95, 107.
 - ▶ Je kostka spravedlivá? (hlas: 8:1 ano)

$$n=600 \quad \theta^* = \left(\frac{1}{6}, \frac{1}{6}, \dots, \frac{1}{6}\right)$$

$$E_i = \frac{1}{5} \cdot 600 = 100$$


$$T = \sum \frac{(X_i - 100)^2}{100} = \frac{8^2}{100} + \frac{20^2}{100} + \frac{12^2}{100} + \frac{2^2}{100} + \frac{5^2}{100} + \frac{2^2}{100}$$

$$Q \sim \chi^2_5$$

$F_Q(0.95) = 11.1 = J$


6.86

$$p\text{-hodnot} = 1 - F_Q \left(\frac{6.86}{T} \right) = 0.23$$



Další rozšíření

- ▶ Pro zkoumání rozdělení libovolné n.v. Y můžeme vybrat „příhrádky“ B_1, \dots, B_k (rozklad \mathbb{R}) a zkoumat, kolikrát je $Y \in B_i$
- ▶ Obdobný test pro nezávislost (diskrétních) náhodných veličin



→ měřit rozdíl.

$$P_i = P(Y \in B_i)$$

probl. počítka: $E_{ij} > 5$,
jeakož neobsazuje

$$\rightarrow T = \sum_i \frac{(X_i - E_i)^2}{E_i}$$

Přehled


Testy dobré shody

Lineární regrese

Bayesovská statistika

Lineární regrese – zadání

- ▶ data: (x_i, y_i) pro $i = 1, \dots, n$
- ▶ cíl: $y = \vartheta_0 + \vartheta_1 x$



- ▶ měříme pomocí kvadratické odchylky

$$\sum_{i=1}^n (y_i - (\vartheta_0 + \vartheta_1 x_i))^2$$

mínimalizace

Lineární regrese – řešení

- Minimalizujeme výraz

$$\sum_{i=1}^n (y_i - (\vartheta_0 + \vartheta_1 x_i))^2$$

- řešení: Optimální parametry jsou

$$\hat{\vartheta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad \hat{\vartheta}_0 = \bar{y} - \hat{\vartheta}_1 \bar{x},$$

kde $\bar{x} := (x_1 + \dots + x_n)/n$, $\bar{y} := (y_1 + \dots + y_n)/n$.

(bez dk - viz A1/(CA))

~~nezávislost, kovariance~~

~~závislost~~

~~závislost průměrů~~

Lineární regrese – proč součet čtverců?

- Předpokládejme, že x_1, \dots, x_n jsou pevná, y_i je zvoleno jako hodnota náhodné veličiny

budování odhad je ϑ_0, ϑ_1

$$Y_i = \underbrace{\vartheta_0 + \vartheta_1 x_i}_{\text{ideální číslo}} + W_i \quad W_i \sim N(0, \sigma^2)$$

- $W_i \sim N(0, \sigma^2)$ pro všechna i ; W_1, \dots, W_k nezávislé.
- metoda maximální věrohodnosti:

$$L(y; \vartheta) = \prod_{i=1}^n \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(y_i - \vartheta_0 - \vartheta_1 x_i)^2}{2\sigma^2}}$$

- $\ell(y; \vartheta) = \log L(y; \vartheta) = a - b \sum_{i=1}^n (y_i - \vartheta_0 - \vartheta_1 x_i)^2$


J

met


$$\ell = \underbrace{n \log \frac{1}{\sigma \sqrt{2\pi}}}_{\text{konst}} - \underbrace{\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \vartheta_0 - \vartheta_1 x_i)^2}_{\text{min}}$$

Limity regrese

OK





stejný příklad, kouzlo



$$y = g(x)$$

↑
kvadratická

outliers



(data: Francis Anscombe 1973, obrázek: wikieditor Schutz)

► nelineární regrese

overfitting
overtraining

$$\sum (y_i - g(x_i))^2$$


blíže k g , tří - minima.
součet čtverec.

Přehled


Testy dobré shody

Lineární regrese

Bayesovská statistika



Bayesova věta



Věta (Bayesova pro jevy)

Pokud B_1, B_2, \dots je rozklad Ω , $A \in \mathcal{F}$ a $P(A), P(B_j) > 0$, tak

$$P(B_j | A) = \frac{P(A | B_j)P(B_j)}{\sum_i P(A | B_i)P(B_i)}.$$

(sčítance s $P(B_i) = 0$ považujeme za 0).

► apriorní, posteriorní pravděpodobnost (prior, posterior)

Věta (Bayesova pro diskrétní náhodné veličiny)

X, Y jsou diskrétní n.v.

$$\frac{P(Y=j | X=x)}{P(Y=j | A)} = p_{Y|X}(y|x) = \frac{p_{X|Y}(x|y)p_Y(y)}{\sum_{y'} p_{X|Y}(x|y')p_Y(y')} = \frac{P(A | B_j)}{P(A | B_i)} \cdot \frac{P(B_j)}{P(B_i)}$$

(sčítance s $p_Y(y') = 0$ považujeme za 0).

Bayesova věta

Věta (Bayesova pro spojité náhodné veličiny)


X, Y jsou spojité n.v., které mají hustotu f_X , f_Y i sdruženou hustotu $\underline{f_{X,Y}}$

$$f_{Y|X}(y|x) = \frac{f_{X|Y}(x|y)f_Y(y)}{\int_{y' \in \mathbb{R}} f_{X|Y}(x|y')f_Y(y')dy'}.$$



(sčítance s $f_Y(y') = 0$ považujeme za 0).

$$\left\{ \begin{aligned} f_{Y|X}(y|x) &= \frac{f_{X|Y}(x|y)f_Y(y)}{\int_{y' \in \mathbb{R}} f_{X|Y}(x|y')f_Y(y')dy'} \\ f_X(x) &= \int_y f_{X|Y}(x|y)f_Y(y)dy \end{aligned} \right.$$



Bayesova věta – zbylé varianty

- X je spojité, Y diskrétní

$$p_{Y|X}(y|x) = \frac{f_{X|Y}(x|y)p_Y(y)}{\sum_{y' \in Im Y} f_{X|Y}(x|y')p_Y(y')}.$$

- X je diskrétní, Y spojité

$$f_{Y|X}(y|x) = \frac{p_{X|Y}(x|y)f_Y(y)}{\int_{y' \in \mathbb{R}} p_{X|Y}(x|y')f_Y(y')dy'}.$$