

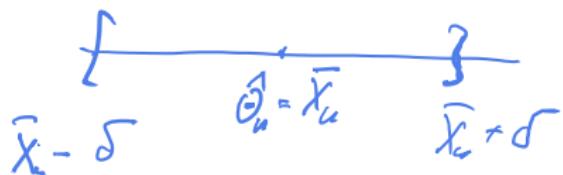
# NMAI059 Pravděpodobnost a statistika 1

## 12. přednáška

Robert Šámal

# Statistika – Co už víme

- ▶ základní nastavení: uvažujeme náhodný výběr  $\underline{X_1, \dots, X_n}$  z distribuce  $F_\vartheta$  — popisuje proces měření, jak mohlo měření proběhnout
  - ▶ naměříme data – konkrétní čísla, tzv. realizaci náhodného výběru  $\underline{x_1, \dots, x_n}$  — jak naše měření skutečně proběhlo
1. bodové odhady: máme určit co nejlepší číslo, odhad pro parametr  $\vartheta$ , nebo nějakou jeho funkci  $g(\vartheta)$ .
  2. intervalové odhady: máme určit interval, ve kterém parametr  $\vartheta$  pravděpodobně leží
  3. testování hypotéz



## Přehled

$n \cdot y \sim N(\mu, \sigma^2)$

$$\begin{aligned} X &\sim N(\mu, \sigma^2) \\ \epsilon &\sim N(0, \sigma^2) \end{aligned}$$
$$X + \epsilon \sim N(\mu + \mu', \sigma^2 + \sigma'^2)$$
$$\Rightarrow -\epsilon \sim N(-\mu, \sigma^2)$$

## Testování hypotéz

$$f_z(z) = \int f_x(x) f_\epsilon(z-x) dx$$

## Testy dobré shody

## Lineární regrese

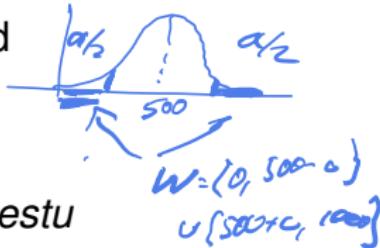
## Testování hypotéz – ilustrace

- ▶ Chceme testovat, zda je mince spravedlivá.
- ▶  $H_0$ : je spravedlivá *očekávaný stav světa*
- ▶  $H_1$ : není spravedlivá *překvapivé zjištění* („Vědci objevili, že v kasinu byla použita falešná mince.“ )
- ▶ Výsledky: zamítneme  $H_0$ /nezamítneme  $H_0$
- ▶ Chyba 1. druhu: chybné zamítnutí. Zamítneme  $H_0$ , i když platí. Trapas.
- ▶ Chyba 2. druhu: chybné přijetí. Nezamítneme  $H_0$ , ale ona neplatí. Promarněná příležitost.
- ▶ Potřebujeme určit  $k$  takové, že budeme zamítat  $H_0$  pokud  $|S - n/2| > k$ .

# Testování hypotéz – obecný postup

$$\text{Hypoteze: } X_1, \dots, X_n \sim \text{Ber}(p)$$
$$H_0: p = \bar{p} \quad H_1: p \neq \bar{p}$$

- ▶ Vybereme vhodný statistický model.
- ▶ Volíme *hladinu významnosti (significance level)  $\alpha$* : pravd. chybného zamítnutí  $H_0$ . Typicky  $\alpha = 0.05$ .
- ▶ Určíme *testovou statistiku  $T = h(X_1, \dots, X_n)$* , kterou budeme určovat z naměřených dat.
- ▶ Určíme *kritický obor (rejection region) – množinu  $W$* .
- ▶ Naměříme hodnoty  $x_1, \dots, x_n$  náh. veličin  $X_1, \dots, X_n$ .
- ▶ Rozhodovací pravidlo: zamítneme  $H_0$  pokud  $h(x_1, \dots, x_n) \in W$ .
- ▶  $\alpha = P(h(X) \in W; H_0)$  crit
- ▶  $\beta = P(h(X) \notin W; H_1)$  ...  $1 - \beta$  je tzv. *síla testu*



- ▶ často  $\alpha$  nevolíme předem, ale spočítáme tzv. *p-hodnotu*: minimální  $\alpha$ , pro které bychom  $H_0$  zamítlí.

$$\text{volme } c : P(T < 500-c) = \alpha/2$$

$$F_T(500-c) = \frac{\alpha}{2}$$
$$[F_T^{-1}(\frac{\alpha}{2})] = 500-c$$

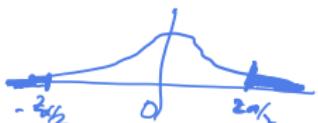
# Testování hypotéz – příklad

- $\underline{X_1, \dots, X_n}$  náhodný výběr z  $\underline{N(\vartheta, \sigma^2)}$
- $\underline{\sigma^2}$  známe,  $\mu$  dán
- $H_0 : \underline{\vartheta = \mu}$        $H_1 : \underline{\vartheta \neq \mu}$

měříme teplotu  
oberec  $\mu = 5^\circ C$

$$T = \frac{\bar{X}_n - \mu}{\sigma} = \bar{X}_n \sim N(\vartheta, \frac{\sigma^2}{n})$$

$$S = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$



$$W = \{ S \in R : |S| > 2\alpha/2 \}$$

$$z_{\alpha/2} = \phi^{-1}(1 - \frac{\alpha}{2}) = 1.96$$

$$\alpha = 0.05$$

... utáma

1. a 2. druhý řád zářice  
zářice pro vodoplyn uva

2. pokud bude ...  $\vartheta = \mu = 5$   
a  $\sigma$  fakticky zářice  $\Rightarrow$   
zářice vodoplynu. T

ZVÁŘÍME!

# Testování hypotéz – příklad dvojvýběrového testu

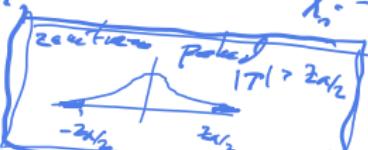
- $X_1, \dots, X_{n_1}$  náhodný výběr z  $Ber(\vartheta_X)$
- $Y_1, \dots, Y_{n_2}$  náhodný výběr z  $Ber(\vartheta_Y)$
- $H_0 : \vartheta_X = \vartheta_Y$        $H_1 : \vartheta_X \neq \vartheta_Y$

$\xrightarrow{\text{dve samostatné lóžky}}$   
 $x_i, y_j$  — zde lóžky  
 lichá  
 výprava —

$$\hat{\vartheta}_X = \frac{X_1 + \dots + X_{n_1}}{n_1} \quad \xrightarrow{\text{odhad } \vartheta_X} \xrightarrow{\text{pravd. norm.}} \text{rozd. CLV}$$

$$\hat{\vartheta}_Y = \frac{Y_1 + \dots + Y_{n_2}}{n_2} \quad \xrightarrow{\text{odhad } \vartheta_Y}$$

$$Z := \hat{\vartheta}_X - \hat{\vartheta}_Y \quad \text{pokud } 121 \text{ je velká,}\br/>
\text{takže } H_0 \text{ zamítáme}$$



$X_i = \{i\text{-ý pacient, který -}\}$   
 dostal I. léčbu  
 se uvolnil\}

$Y_j = \{j\text{-ý pac. -}\}$   
 II. léčbu  
 se uvolnil\}

Pokud platí  $H_0$      $E \hat{\vartheta}_X = E \hat{\vartheta}_Y \Rightarrow E Z = 0$

$$\sigma_Z = \sqrt{\text{var}(Z)} = \sqrt{\text{var}(\hat{\vartheta}_X) + \text{var}(\hat{\vartheta}_Y)} = \sqrt{\frac{\text{var}(X_1)}{n_1} + \frac{\text{var}(Y_1)}{n_2}} \xrightarrow{\text{z je pravd. } N(0, \sigma^2)} \text{nezávislá} \quad \sigma^2 = (1-\vartheta)$$

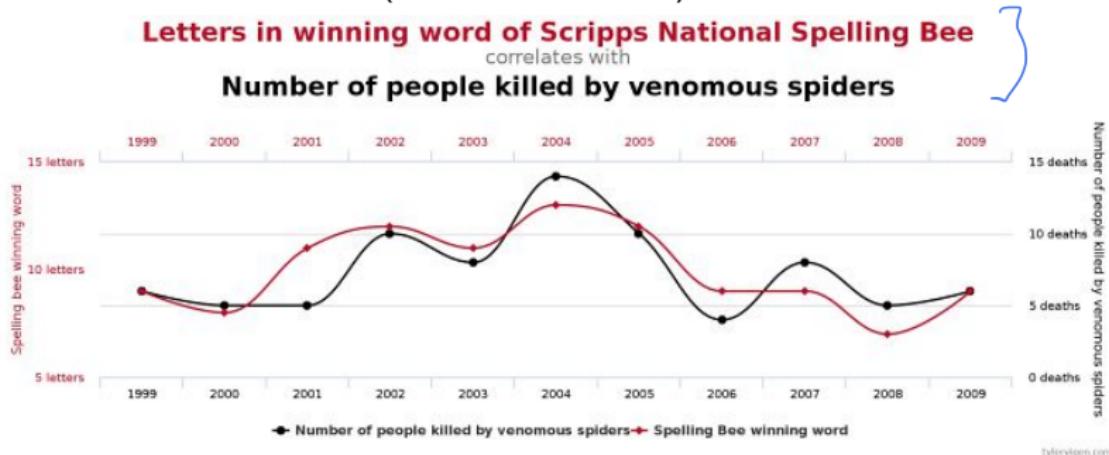
$$\hat{\vartheta} = \text{var}(Z) = \text{var}(\hat{\vartheta}_X) + \text{var}(\hat{\vartheta}_Y) = \frac{\text{var}(X_1)}{n_1} + \frac{\text{var}(Y_1)}{n_2} = \frac{\vartheta_1(1-\vartheta_1)}{n_1} + \frac{\vartheta_2(1-\vartheta_2)}{n_2} = \frac{\vartheta_1 + \vartheta_2}{n_1 + n_2}$$

$$\hat{\vartheta} = \frac{\sum X_i + \sum Y_j}{n_1 + n_2} \quad \text{odhad } \vartheta \Rightarrow \hat{\vartheta}^* := \left(\frac{1}{n_1} + \frac{1}{n_2}\right) \hat{\vartheta} (1 - \hat{\vartheta}) \Rightarrow T := \frac{\hat{\vartheta}_1 - \hat{\vartheta}_2}{\hat{\vartheta}} = \frac{\hat{\vartheta}_1 - \hat{\vartheta}_2}{\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim N(0, 1)$$

# *p*-hacking

- ▶ napřed získáme data, pak v nich hledáme zajímavosti
- ▶ když máme dost dat, tak tam nějaké budou „shodou okolností“
- ▶ *reprodukelnost* – po explorační analýze dat uděláme nezávislý sběr dat a ten analyzujeme konfirmačně
- ▶ nebo dopředu náhodně rozdělíme data na část pro tvorbu hypotéz a část pro jejich potvrzení ... jednoduchý případ křížové validace (cross validation)

**Letters in winning word of Scripps National Spelling Bee**  
correlates with  
**Number of people killed by venomous spiders**



# Přehled

Testování hypotéz

Testy dobré shody

Lineární regrese

$\chi_k^2$  – rozdělení  $\chi$ -kvadrát

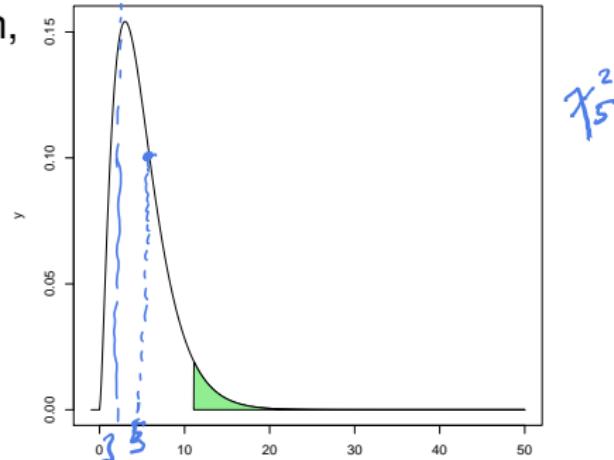
### Definice

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

$$Q = Z_1^2 + \dots + Z_k^2$$

se nazývá  $\chi$ -kvadrát s  $k$  stupni volnosti. (Opravdu  $k$ !)

- ▶  $\mathbb{E}(Q) = k$  (lehké)
- ▶  $var(Q) = 2k$  (pro info, netřeba pamatovat)
- ▶ hustota jde napsat vzorcem, jde najít např. na Wikipedii
- ▶  $Q \doteq N(k, 2k)$  pro velká  $k$  (CLV)



# Multinomické a kategoriální rozdělení

vsledek  
výsledek  
zpráva  
k

## 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  $n, (p_1, \dots, p_k)$ .

- ▶ triviální případ:  $X_i =$  počet hodů kostkou, kdy padlo  $i$
- ▶ důležitý případ:  $X_i =$  počet výskytů  $i$ -tého písmene,  $i$ -tého slovního druhu, ...
- ▶  $P(X_1 = x_1, \dots, X_k = x_k) = \underbrace{\binom{n}{x_1, \dots, x_k} p_1^{x_1} \cdots p_k^{x_k}}$

# Pearsonova $\chi^2$ 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  $\chi^2$  statistika je funkce  $O_i \dots \text{observed}$

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

*k period, n → ∞*

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

Dle pro  $k=2$   $X_1 + X_2 = n, P_1 + P_2 = 1, E_1 = nP_1, -X_1 + nP_1$

$$T = \frac{(X_1 - \bar{E}_1)^2}{\bar{E}_1} + \frac{(X_2 - \bar{E}_2)^2}{\bar{E}_2} = \frac{(X_1 - nP_1)^2}{nP_1 P_2} + \frac{(n - X_1 - n(1-P_1))^2}{nP_2 P_1} = \frac{(X_1 - nP_1)^2}{nP_1 P_2}$$
$$= \left( \frac{X_1 - nP_1}{\sqrt{n(P_1 - P_2)}} \right)^2 \xrightarrow{d} N(0,1) \text{ podle CLT}$$

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

$$\xrightarrow{\text{d}} \chi_{k-1}^2$$



# Test dobré shody – příklad

- Házíme opakováně kostkou. Jednotlivá čísla padla s četností 92, 120, 88, 98, 95, 107.
- Je kostka spravedlivá?

$$n = 92 + 120 + \dots = 600 \quad \vartheta = \left( \frac{1}{6}, \dots, \frac{1}{6} \right), \quad E_i = \frac{n}{6} = 100$$
$$T = \sum_{i=1}^6 \frac{(X_i - 100)^2}{100} = \frac{(92-100)^2}{100} + \frac{(120-100)^2}{100} + \frac{88^2}{100} + \frac{98^2}{100} + \frac{95^2}{100} + \frac{107^2}{100}$$

$$\underline{\underline{= (9^2 + 20^2 + 12^2 + 2^2 + 5^2 + 7^2) / 100}} = \underline{\underline{6.86}}$$

$$Q \sim \chi_{\alpha}^2 \quad F_Q^{-1}(0.95) = 11.1 = J$$

$$\text{p-hodnota: } 1 - F_Q(6.86) = 1 - 0.72 = 0.23$$

G-test

## Další rozšíření

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



# Přehled

Testování hypotéz

Testy dobré shody

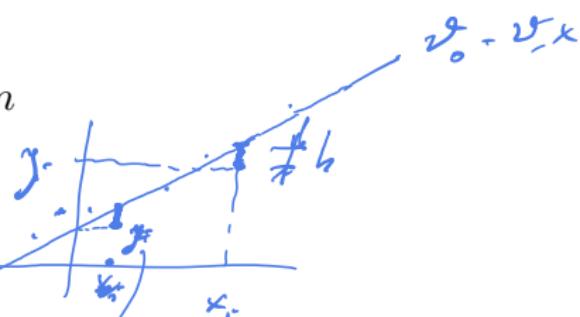
Lineární regrese

# Lineární regrese – zadání

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

šk. funkce:

$$y = \vartheta_0 + \vartheta_1 x + \text{náh. chyba}$$



- ▶ měříme pomocí kvadratické odchylky

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

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

$$\frac{\frac{1}{n-1} \sum (x_i - \bar{x})(y_i - \bar{y})}{\frac{1}{n-1} \sum (x_i - \bar{x})^2}$$

--- *geometrická kovariance*

--- *výberový koeficient*

# Lineární regrese – proč součet čtverců?

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

$$Y_i = \vartheta_0 + \vartheta_1 x_i + W_i$$

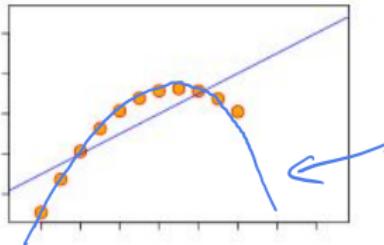
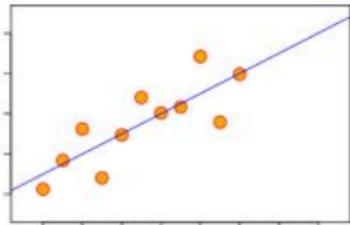
- ▶  $W_i \sim N(0, \sigma^2)$  pro všechna  $i$ ;  $W_1, \dots, W_k$  nezávislé.
- ▶ metoda maximální věrohodnosti:

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

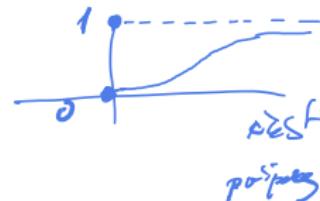
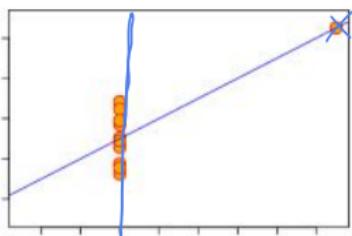
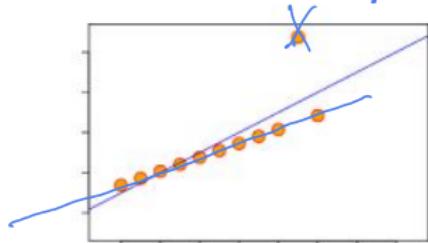
- ▶  $\ell(y; \vartheta) = \log L(y; \vartheta) = a + b \sum_{i=1}^n (y_i - \vartheta_0 - \vartheta_1 x_i)^2$

# Limity regrese

#body



čas ne  
pravidelný



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

► nelineární regrese

→ logistická regrese

..... ~~regrese~~

$x_i$  -- reálné čísla

$y_i$  -- 0/1

# Simpsonův paradox

Treatment Stone size \	Treatment A	Treatment B
Small stones	Group 1 93% (81/87)	Group 2 87% (234/270)
Large stones	Group 3 73% (192/263)	Group 4 69% (55/80)
Both	78% (273/350)	83% (289/350)

