

M5120 Lineární statistické modely I

Poznámky do cvičení

Ondřej Pokora (pokora@math.muni.cz)

Ústav matematiky a statistiky, Přírodovědecká fakulta, Masarykova univerzita, Brno

podzim 2013 (aktualizace 16.12.2013)



Maximálně věrohodné odhady

Náhodný výběr X_1, \dots, X_n rosahu n z rozdělení pravděpodobnosti P :

- ▶ $X \sim P (i = 1, \dots, n)$
- ▶ X_1, \dots, X_n jsou stochasticky nezávislé
- ▶ Co to znamená pro vztah mezi simultánní a marginální hustotou pravděpodobnosti $f(x)$ (pravděpodobnostní funkci $p(x)$) ?

Rozdělení pravděpodobnosti závislé na parametru (parametrech) θ :

- ▶ $f(x), p(x)$ jako funkce proměnné $\theta \Rightarrow L(\theta)$
- ▶ Věrohodnostní funkce $L(\theta)$ a logaritmická věrohodnostní funkce $l(\theta)$:

$$L(\theta) = L(\theta; x_1, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n p(x_i; \theta)$$

$$l(\theta) = l(\theta; x_1, \dots, x_n) = \ln L(\theta; x_1, \dots, x_n) = \sum_{i=1}^n \ln f(x_i; \theta) = \sum_{i=1}^n \ln p(x_i; \theta)$$

- ▶ Jak odhadnout θ ze znalosti X_1, \dots, X_n ?

Maximálně věrohodné odhady

Myšlenka: parametr θ odhadneme hodnotou, která je při daném náhodném výběru ze známého rozdělení pravděpodobnosti nejvíce pravděpodobná.

Maximálně věrohodný odhad (MLE = maximum likelihood estimator) $\hat{\theta}_{\text{ML}}$ parametru θ se získá maximalizací věrohodnostní funkce $L(\theta)$:

$$\hat{\theta}_{\text{ML}} : L(\theta; x_1, \dots, x_n) \rightarrow \max_{\theta}, \quad \text{resp. } l(\theta; x_1, \dots, x_n) \rightarrow \max_{\theta}$$

To znamená najít stacionární bod funkce $l(\theta)$ vzhledem k θ ,

$$\frac{\partial}{\partial \theta} l(\theta) = 0 \quad (\text{věrohodnostní rovnice}),$$

a ověřit 2. diferenciál, resp. derivaci,

$$\left. \frac{\partial^2}{\partial \theta^2} l(\theta) \right|_{\theta=\hat{\theta}_{\text{ML}}} < 0 .$$

Poznámka: v případě vektoru parametrů θ řešíme soustavu věrohodnostních rovnic pro θ z 1. derivací a ověřujeme negativní definitnost matice 2. derivací.

MLE – příklady (1)

- 1.** Najděte ML-odhad parametru $\theta \in [0, 1]$ pro náhodný výběr X_1, \dots, X_n z binomického rozdělení $\text{Bi}(N, \theta)$ ($N \in \mathbb{N}$ známé) s pravděpodobnostní funkcí

$$p(x) = \binom{N}{x} \theta^x (1 - \theta)^{N-x} \quad \text{pro } x = 0, 1, \dots, N; \quad p(x) = 0 \quad \text{jinak.}$$

- 2.** Najděte ML-odhad parametru $\theta \in [0, 1]$ pro náhodný výběr X_1, \dots, X_n z geometrického rozdělení $\text{Ge}(\theta)$ s pravděpodobnostní funkcí

$$p(x) = (1 - \theta)^x \theta \quad \text{pro } x \in \mathbb{N}_0; \quad p(x) = 0 \quad \text{jinak.}$$

- 3.** Najděte ML-odhad parametrů $\mu \in \mathbb{R}$ a $\sigma^2 > 0$ pro náhodný výběr X_1, \dots, X_n z Gaussova rozdělení $\text{N}(\mu, \sigma^2)$ s hustotou pravděpodobnosti

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x-\mu)^2}{2\sigma^2}\right].$$

- 4.** Najděte ML-odhad parametrů $\mu \in \mathbb{R}$ a $\sigma^2 > 0$ pro náhodný výběr X_1, \dots, X_n z logaritmického normálního rozdělení $\text{LN}(\mu, \sigma^2)$:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}x} \exp\left[-\frac{(\ln x - \mu)^2}{2\sigma^2}\right] \quad \text{pro } x > 0; \quad f(x) = 0 \quad \text{jinak.}$$

MLE – příklady (2)

- 5.** Najděte ML-odhad parametru $\mu > 0$ pro náhodný výběr X_1, \dots, X_n z exponenciálního rozdělení $\text{Ex}(\mu)$ s hustotou pravděpodobnosti

$$f(x) = \frac{1}{\mu} \exp\left[-\frac{x}{\mu}\right] \quad \text{pro } x \geq 0; \quad f(x) = 0 \quad \text{jinak.}$$

- 6.** Najděte ML-odhad parametru $\lambda > 0$ pro náhodný výběr X_1, \dots, X_n z exponenciálního rozdělení $\text{Ex}(\lambda)$ s hustotou pravděpodobnosti

$$f(x) = \lambda \exp[-\lambda x] \quad \text{pro } x \geq 0; \quad f(x) = 0 \quad \text{jinak.}$$

- 7.** Najděte ML-odhad parametrů $\lambda > 0$ a $k > 0$ pro náhodný výběr X_1, \dots, X_n z Weibullovou rozdělení $\text{Wb}(\lambda, k)$ s hustotou pravděpodobnosti

$$f(x) = k \lambda x^{k-1} \exp[-\lambda x^k] \quad \text{pro } x \geq 0; \quad f(x) = 0 \quad \text{jinak.}$$

- 8.** Najděte ML-odhad parametru $s > 0$ pro náhodný výběr X_1, \dots, X_n z Rayleighova rozdělení $\text{Ra}(s)$ s hustotou pravděpodobnosti

$$f(x) = \frac{x}{s} \exp\left[-\frac{x^2}{2s}\right] \quad \text{pro } x \geq 0; \quad f(x) = 0 \quad \text{jinak.}$$

MLE – příklady (3)

9. Najděte ML-odhad parametru $\lambda > 0$ pro náhodný výběr X_1, \dots, X_n z Gamma rozdělení $\Gamma(\lambda, k)$ ($k > 0$) s hustotou pravděpodobnosti

$$f(x) = \frac{\lambda^k}{\Gamma(k)} x^{k-1} \exp[-\lambda x] \quad \text{pro } x \geq 0; \quad f(x) = 0 \quad \text{jinak.}$$

Najděte také věrohodnostní rovnici pro ML-odhad k .

Pomůcka: $\frac{\partial}{\partial k} \ln \Gamma(k) = \Psi(k)$ = digamma funkce.

- *. Další příklady pro odvození ML-odhadů parametrů v rozděleních s podobnými tvary hustot naleznete na stránce dr. Forbelšké.

MLE – řešení příkladů

1. $\hat{\theta}_{\text{ML}} = \frac{\bar{X}}{N}$

2. $\hat{\theta}_{\text{ML}} = \frac{1}{1 + \bar{X}}$

3. $\hat{\mu}_{\text{ML}} = \bar{X} , \quad \hat{\sigma^2}_{\text{ML}} = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu}_{\text{ML}})^2$

4. $\hat{\mu}_{\text{ML}} = \frac{1}{n} \sum_{i=1}^n \ln X_i , \quad \hat{\sigma^2}_{\text{ML}} = \frac{1}{n} \sum_{i=1}^n (\ln X_i - \hat{\mu}_{\text{ML}})^2$

5. $\hat{\lambda}_{\text{ML}} = \bar{X}$

6. $\hat{\lambda}_{\text{ML}} = \frac{1}{\bar{X}}$

7. $\hat{\lambda}_{\text{ML}} = \frac{n}{\sum_{i=1}^n X_i^k}$

8. $\hat{s}_{\text{ML}} = \frac{1}{2n} \sum_{i=1}^n X_i^2$

9. $\hat{\lambda}_{\text{ML}} = \frac{k}{\bar{X}} , \quad \text{ML-rovnice pro } k: \Psi(\hat{k}_{\text{ML}}) = \ln \lambda + \bar{X}$

Odhady parametrů momentovou metodou

Odhady parametrů tzv. **metodou momentů** spočívá ve vyjádření několika prvních (tolik, kolik potřebujeme) **momentů M_p** rozdělení pravděpodobnosti náhodné veličiny X ,

$$M_p = \mathbb{E}(X^p) \quad (p = 1, 2, \dots)$$

Teoretické momenty M_p závisí na neznámých parametrech, které chceme odhadnout.

Momenty M_p v rovnici (rovnících) nahradíme (aproximujeme)
výběrovými momenty m_p ,

$$m_p = \frac{1}{n} \sum_{i=1}^n X_i^p \quad (p = 1, 2, \dots)$$

které závisí pouze na náhodném výběru. Algebraickým vyjádřením (příp. numerickým výpočtem) hledaných parametrů z rovnice (systému rovnic) pro m_p obdržíme odhady $\widehat{\theta}_M$ momentovou metodou.

Momentové odhady – příklady

Jako cvičení spočtěte odhady parametrů momentovou metodou v příkladech

1.–9. pro maximálně věrohodné odhady.

Nejdříve odvoděte (pro hustoty integrováním), nebo pomocí tabulek či počítače nalezněte, momenty daných rozdělení pravděpodobnosti,

$$M_p = E(X^p) \quad (p = 1, 2, \dots)$$

Pro kontrolu jsou první dva momenty M_1, M_2 uvedeny v tabulce vpravo.

Poté odvoděte momentové odhady parametrů a porovnejte je s maximálně věrohodnými odhady.

příklad	M_1	M_2
1.	$N\theta$	$N\theta(1-\theta)$
2.	$\frac{1-\theta}{\theta}$	$\frac{(1-\theta)^2+(1-\theta)}{\theta^2}$
3.	μ	$\mu^2 + \sigma^2$
4.	$\exp \left[\mu + \frac{1}{2}\sigma^2 \right]$	$\exp [2\mu + 2\sigma^2]$
5.	μ	$2\mu^2$
6.	$\frac{1}{\lambda}$	$\frac{2}{\lambda^2}$
7.	$\frac{1}{k} \lambda^{-\frac{1}{k}} \Gamma \left(\frac{1}{k} \right)$	$\lambda^{-\frac{2}{k}} \Gamma \left(1 + \frac{2}{k} \right)$
8.	$\sqrt{\frac{\pi s}{2}}$	$2s$
9.	$\frac{k}{\lambda}$	$\frac{k(k+1)}{\lambda^2}$

Momentové odhady – řešení příkladů

Označení: p -tý výběrový moment = $m_p = \frac{1}{n} \sum_{i=1}^n X_i^p$ ($p = 1, 2, \dots$)

1. $\hat{\theta}_M = \frac{m_1}{N}$

2. $\hat{\theta}_M = \frac{1}{1 + m_1}$

3. $\hat{\mu}_M = m_1 , \quad \hat{\sigma^2}_M = m_2 - m_1^2$

4. $\hat{\mu}_M = 2 \ln m_1 - \frac{1}{2} \ln m_2 , \quad \hat{\sigma^2}_M = \ln m_2 - 2 \ln m_1$

5. $\hat{\lambda}_M = m_1$

6. $\hat{\lambda}_M = \frac{1}{m_1}$

8. $\hat{s}_M = \frac{2m_1^2}{\pi} , \text{ anebo } \hat{s}_M = \frac{m_2}{2}$

9. $\hat{\lambda}_M = \frac{m_1}{m_2 - m_1^2} , \quad \hat{k}_M = \frac{m_1^2}{m_2 - m_1^2}$

Náhodné vektory

Náhodný vektor $\mathbf{X} = (X_1, \dots, X_n)'$ (reálný) je měřitelná vektorová funkce $\mathbf{X} = (X_1, \dots, X_n)': \Omega \rightarrow \mathbb{R}^n$, jejíž složky jsou náhodné veličiny, $X_i : \Omega \rightarrow \mathbb{R}$, na stejném pravděpodobnostním prostoru (Ω, \mathcal{A}, P) .

Střední hodnota $E(\mathbf{X})$ náhodného vektoru je definována po složkách:

$$E(\mathbf{X}) = (E(X_1), \dots, E(X_n))'.$$

Kovarianční matici $\text{cov}(\mathbf{X})$ (*variance-covariance matrix*) náhodného vektoru:

$$\mathbf{D}(\mathbf{X}) = \text{cov}(\mathbf{X}) = \{c_{i,j}\}_{i,j=1}^n , \quad \text{kde } c_{i,j} = C(X_i, X_j) .$$

- ▶ $\text{cov}(\mathbf{X})$ je čtvercová řádu n , symetrická (proč?)
- ▶ hlavní diagonálu tvoří rozptyly $D(X_i)$, ostatní složky jsou kovariance $C(X_i, X_j)$
- ▶ pozitivně semidefinitní, tzn. $\forall \mathbf{u} \in \mathbb{R}^n : \mathbf{u}' \text{cov}(\mathbf{X}) \mathbf{u} \geq 0$

Poznámka: Anglická literatura často užívá společný pojem *variance* (var, Var). Potom rozumíme: $\text{var}(X) = D(X)$ pro náhodnou veličinu a $\text{var}(\mathbf{X}) = \text{cov}(\mathbf{X})$ pro náhodný vektor.

Jednoduché transformace náhodných vektorů

Lineární transformace $\mathbb{R}^n \rightarrow \mathbb{R}^m$:

$$\begin{aligned}\mathbb{E}(\boldsymbol{a} + B\mathbf{X}) &= \boldsymbol{a} + B\mathbb{E}(\mathbf{X}) \\ \text{cov}(\boldsymbol{a} + B\mathbf{X}) &= B \text{cov}(\mathbf{X}) B'\end{aligned}$$

Lineární forma $\mathbb{R}^n \rightarrow \mathbb{R}$:

$$\begin{aligned}\mathbb{E}(\boldsymbol{a} + \boldsymbol{b}'\mathbf{X}) &= \boldsymbol{a} + \boldsymbol{b}'\mathbb{E}(\mathbf{X}) \\ \mathbb{D}(\boldsymbol{a} + \boldsymbol{b}'\mathbf{X}) &= \boldsymbol{b}' \text{cov}(\mathbf{X}) \boldsymbol{b}\end{aligned}$$

Kvadratická forma $\mathbb{R}^n \rightarrow \mathbb{R}$:

$$\mathbb{E}(\mathbf{X}' A \mathbf{X}) = \mathbb{E}(\mathbf{X})' A \mathbb{E}(\mathbf{X}) + \text{Tr}[A \text{cov}(\mathbf{X})]$$

$\boldsymbol{a} \in \mathbb{R}^m$; $B \in \mathbb{R}^{n \times m}$; $a \in \mathbb{R}$; $\boldsymbol{b} \in \mathbb{R}^m$; $A \in \mathbb{R}^{n \times n}$ pozitivně definitní

Stopa (Trace) matice $= \text{Tr}(C) = \sum_{i=1}^n \{c_{i,i}\}$
Platí: $\text{Tr}(ABC) = \text{Tr}(BCA) = \text{Tr}(CAB)$

Známé vzorce ve vektorové (maticové) formě

- ▶ i -tá složka náhodného vektoru

$$X_i = e'_i X, \quad \text{kde } e_i = (0_1, \dots, 0_{i-1}, 1_i, 0_{i+1}, \dots, 0_n)' \text{ je jednotkový vektor}$$

- ▶ výběrový průměr

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} (1, \dots, 1) X = \left(\frac{1}{n}, \dots, \frac{1}{n} \right) X$$

- ▶ druhý výběrový moment

$$\frac{1}{n} \sum_{i=1}^n X_i^2 = \frac{1}{n} X' I_n X, \quad \text{kde } I_n \text{ je jednotková matice řádu } n$$

- ▶ čtverec výběrového průměru

$$(\bar{X})^2 = \bar{X}' \bar{X} = \frac{1}{n^2} X' J_n X, \quad \text{kde } J_n = \{1\}_{i,j=1}^n \text{ je matice jedniček}$$

Náhodné vektory – příklady (1)

V následujících příkladech spočítejte $E(\mathbf{X})$, $\text{cov}(\mathbf{X})$ náhodného vektoru \mathbf{X} :

13. Znáte: $E(X_i) = 10i$, $C(X_i, X_j) = ij$, ($i, j = 1, 2$).
14. Znáte: $E(X_i) = 10i$, $D(X_i) = i^2$, ($i, j = 1, 2, 3$); $R(X_i, X_j) = 0,5$ pro $i \neq j$.
15. \mathbf{X} je náhodný výběr rozsahu 4 z rozdělení $N(10, 4)$.
16. \mathbf{X} je náhodný výběr rozsahu 5 z rozdělení $Ex(\lambda)$.

17. Znáte: $E \begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} = \begin{pmatrix} 20 \\ 30 \\ 2 \end{pmatrix}$, $\text{cov} \begin{pmatrix} X_1 \\ X_2 \\ X_3 \end{pmatrix} = \begin{pmatrix} 100 & 0 & 25 \\ ? & 9 & ? \\ ? & 9 & 16 \end{pmatrix}$. Spočítejte střední hodnoty, rozptyly, kovariance, korelační koeficienty náhodných veličin X_1, X_2, X_3 . Které dvojice (trojice) veličin jsou stochasticky nezávislé?

18. V příkladu 17., s využitím vhodných transformací, spočítejte:

- ▶ $E(10X_3)$
- ▶ $D(10X_3)$
- ▶ $E(2X_1 - 5X_3 - X_2)$
- ▶ $D(2X_1 - 5X_3 - X_2)$
- ▶ $C(10X_3, 2X_1 - 5X_3 - X_2)$
- ▶ $R(10X_3, 2X_1 - 5X_3 - X_2)$
- ▶ $C(X_1 + X_2, X_3 - X_2)$
- ▶ $R(X_1 + X_2, X_3 - X_2)$

Náhodné vektory – příklady (3)

- 23.** Spočtěte střední hodnotu $m = E(Y_1^2 + Y_2^2 + Y_3^2)$ a kovarianční matici $\text{cov}(\mathbf{Y})$, kde $Y_1 = X_1$, $Y_2 = X_1 + X_2$, $Y_3 = X_1 + X_2 + X_3$ jsou transformace vzájemně nezávislých náhodných veličin X_1, X_2, X_3 , $E(X_1) = 10$, $E(X_2) = 20$, $E(X_3) = 30$, $D(X_1) = 1$, $D(X_2) = 4$, $D(X_3) = 9$.
- 24.** Spočtěte střední hodnotu $m = E(Y_1Y_2 + Y_2Y_3 + Y_3Y_1)$ a kovarianční matici $\text{cov}(\mathbf{Y})$, kde $Y_1 = X_2 + X_3$, $Y_2 = X_1 + X_3$, $Y_3 = X_1 + X_2$ jsou transformace vzájemně nekorelovaných složek náhodného vektoru \mathbf{X} , $E(\mathbf{X}) = (10, 10, 10)'$, $D(X_i) = i^2$.
- 25.** Spočtěte $E(\mathbf{Y})$, $\text{cov}(\mathbf{Y})$ a $m = E(Y_1^2 + Y_2^2 + Y_3^2 + Y_4^2 + 2Y_1Y_4)$, kde X_1, X_2, X_3, X_4 jsou náhodné veličiny, $E(X_i) = 10$, $C(X_i, X_j) = 1$. Známe transformační vztahy $X_1 = Y_1$, $X_2 = Y_2 - Y_1$, $X_3 = Y_3 - Y_2$, $X_4 = Y_4 - Y_3$.
- 26.** Spočítejte střední hodnotu povrchu hranolu s podstavou tvaru čtverce. Délka hrany podstavy je náhodná veličina se střední hodnotou 10 a rozptylem 1, výška hranolu je náhodná veličina se střední hodnotou 20 a rozptylem 9 a její korelační koeficient s délkou hrany podstavy je 0,1.

Náhodné vektory – příklady (3)

- 19.** Ověřte, pro že výběrový průměr \bar{X} náhodného výběru rozsahu n z rozdělení se střední hodnotou μ a rozptylem σ^2 platí: $E(\bar{X}) = \mu$, $D(\bar{X}) = \sigma^2/n$.
- 20.** Ověřte, že pro výběrový rozptyl S_X^2 náhodného výběru rozsahu n z rozdělení $N(\mu, \sigma^2)$ platí: $E(S_X^2) = \sigma^2$.
Bonusová těžší úloha: ověřte, že $D(S_X^2) = 2\sigma^4/(n - 1)$.
- 21.** Ověřte, pro že pro náhodný výběr rozsahu n z rozdělení se střední hodnotou μ a rozptylem σ^2 platí vztah $E[3Q_1 - Q_2] = (n - 3)\sigma^2$, kde $Q_1 = \sum_{i=1}^n (X_i - \bar{X})^2$ a $Q_2 = (X_n - X_1)^2 + \sum_{i=2}^{n-1} (X_i - X_{i-1})^2$.
- 22.** Spočítejte $E(Y)$ a $\text{cov}(Y)$ transformovaného náhodného vektoru

$$Y = \begin{pmatrix} -1 \\ 1 \\ 0 \end{pmatrix} + \begin{pmatrix} 1 & 1 \\ -1 & 2 \\ 0 & 10 \end{pmatrix} X, \text{ když } E(X) = \begin{pmatrix} 0 \\ 10 \end{pmatrix}, \text{cov}(X) = \begin{pmatrix} 1 & 1 \\ 1 & 4 \end{pmatrix} .$$

Náhodné vektory – řešení příkladů

- 18.**
- ▶ $E(10 X_3) = 20$
 - ▶ $E(2 X_1 - 5 X_3 - X_2) = 0$
 - ▶ $C(10 X_3, 2 X_1 - 5 X_3 - X_2) = -390$
 - ▶ $C(X_1 + X_2, X_3 - X_2) = 25$
 - ▶ $D(10 X_3) = 1600$
 - ▶ $D(2 X_1 - 5 X_3 - X_2) = 399$
 - ▶ $R(10 X_3, 2 X_1 - 5 X_3 - X_2) \approx -0,488$
 - ▶ $R(X_1 + X_2, X_3 - X_2) \approx 0,905$

22. $E(\mathbf{Y}) = \begin{pmatrix} 9 \\ 21 \\ 100 \end{pmatrix}, \text{ cov}(\mathbf{Y}) = \begin{pmatrix} 7 & 8 & 50 \\ 8 & 13 & 70 \\ 50 & 70 & 400 \end{pmatrix}$

23. $m = 4600 + 20 = 4620, \text{ cov}(\mathbf{Y}) = \begin{pmatrix} 1 & 1 & 1 \\ 1 & 5 & 5 \\ 1 & 5 & 14 \end{pmatrix}$

24. $m = 1200 + 14 = 1214, \text{ cov}(\mathbf{Y}) = \begin{pmatrix} 13 & 9 & 4 \\ 9 & 10 & 1 \\ 4 & 1 & 5 \end{pmatrix}$

25. $E(\mathbf{Y}) = \begin{pmatrix} 10 \\ 20 \\ 30 \\ 40 \end{pmatrix}, m = 3800 + 38 = 3838, \text{ cov}(\mathbf{Y}) = \begin{pmatrix} 1 & 2 & 3 & 4 \\ 2 & 4 & 6 & 8 \\ 3 & 6 & 9 & 12 \\ 4 & 8 & 12 & 16 \end{pmatrix}$

26. Střední hodnota povrchu uvedeného hranolu je rovna $1000 + 3,2 = 1003,2$.

Lineární regresní model (LRM)

- ▶ popisuje lineární závislost

$$Y = \beta_0 + \sum_{j=1}^p \beta_j x_j + \varepsilon$$

- ▶ Y je závislá proměnná, náhodná veličina
- ▶ x_1, \dots, x_p jsou nenáhodné vysvětlující proměnné, tzv. regresory
- ▶ ε je náhodná chyba, $E(\varepsilon) = 0$, s neznámým konstatním rozptylem $D(\varepsilon) = \sigma^2$
- ▶ $\beta_0, \beta_1, \dots, \beta_p$ jsou neznámé parametry
- ▶ úkol regresní analýzy: na základě opakovaných měření závislé proměnné za různých hodnot regresorů optimálně určit parametry $\beta_0, \beta_1, \dots, \beta_p$ modelu
- ▶ předpokládáme, že měření je opakováno n krát, tzn. pro $i = 1, \dots, n$ máme:

$$Y_i = \beta_0 + \sum_{j=1}^p \beta_j x_{i,j} + \varepsilon_i$$

- ▶ náhodné chyby $\varepsilon_1, \dots, \varepsilon_n$ jsou nezávislé stejně rozdělené náhodné veličiny (i.i.d.)

LRM ($\mathbf{Y}, \mathbf{X}\boldsymbol{\beta}, \sigma^2 I$) plné hodnoty

- ▶ $Y_i = \beta_0 + \sum_{j=1}^p \beta_j x_{i,j} + \varepsilon_i$ v maticovém tvaru:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad \underbrace{\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix}}_{\mathbf{Y}} = \underbrace{\begin{pmatrix} 1 & x_{1,1} & \dots & x_{1,p} \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ 1 & x_{n,1} & \dots & x_{n,p} \end{pmatrix}}_{\mathbf{X}} \cdot \underbrace{\begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}}_{\boldsymbol{\beta}} + \underbrace{\begin{pmatrix} \varepsilon_1 \\ \vdots \\ \vdots \\ \varepsilon_n \end{pmatrix}}_{\boldsymbol{\varepsilon}}$$

- ▶ \mathbf{Y} je náhodný vektor n pozorování
- ▶ regresory tvoří nenáhodnou $n \times k$ matici plánu (*design matrix*) \mathbf{X}
- ▶ $\boldsymbol{\beta}$ je vektor $k = p + 1$ neznámých parametrů
- ▶ závislost je lineární vzhledem k parametrům β_j
- ▶ vektor náhodných chyb má kovariační matici $D(\boldsymbol{\varepsilon}) = \sigma^2 I_n$
- ▶ $n > k = p + 1$, tj. počet pozorování je větší než počet parametrů
- ▶ matice plánu je plné hodnoty: $h(\mathbf{X}) = k = p + 1$

Metoda nejmenších čtverců (MNČ)

- ▶ V LRM $\mathbf{Y} = \mathbf{X}\beta + \epsilon$ chceme najít vektor parametrů β tak, aby naměřené hodnoty \mathbf{Y} byly optimálně approximovány vektorem $\mathbf{X}\beta$.
- ▶ Metoda nejmenších čtverců (*ordinary least-square method*) stanovuje odhad $\hat{\beta}$ jako bod minima penalizační funkce, která je součtem čtverců odchylek:

$$\sum_{i=1}^n \left(Y_i - \beta_0 - \sum_{j=1}^p x_{i,j} \beta_j \right)^2 = (\mathbf{Y} - \mathbf{X}\beta)'(\mathbf{Y} - \mathbf{X}\beta) \longrightarrow \min_{\beta} \implies \hat{\beta}$$

- ▶ Při splnění podmínek pro LRM plné hodnosti existuje vždy právě jedno řešení této minimalizační úlohy. To lze nalézt vyřešením soustavy normálních rovnic

$$\mathbf{X}'\mathbf{X}\beta = \mathbf{X}'\mathbf{Y}$$

- ▶ Odhad vektoru parametrů v LRM metodou nejmenších čtverců je tedy tvaru

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

Poznámka: při numerických výpočtech se inverzní matice nepočítá přímo, ale využívá se např. Q-R rozkladu.

Veličiny v LRM (1)

- ▶ Aproximované hodnoty závislé proměnné (*fitted values, Y-hat*)

$$\hat{\mathbf{Y}} = \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

- ▶ Rezidua (*residuals*): $\mathbf{r} = \mathbf{Y} - \hat{\mathbf{Y}}$
- ▶ Reziduální součet čtverců

$$S_e = \sum_{i=1}^n r_i^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \mathbf{r}'\mathbf{r} = (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})$$

kvantifikuje velikost variability, kterou se nepodařilo LRM vysvětlit.

- ▶ Odhad rozptylu σ^2 náhodných chyb

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

- ▶ Standardní reziduální chyba (*residual standard error*): $\hat{\sigma} = s = \sqrt{s^2}$

Veličiny v LRM (2)

- ▶ Regresní součet součet čtverců

$$S_r = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$$

kvantifikuje velikost variability, kterou se LRM podařilo zachytit. Je dán součtem kvadrátů odchylek approximovaných hodnot od výběrového průměru.

- ▶ Celkový součet součet čtverců je násobkem výběrového rozptylu:

$$S_t = \sum_{i=1}^n (Y_i - \bar{Y})^2 = (n - 1)S_Y^2$$

- ▶ Platí: $S_t = S_r + S_e$

Koeficient determinace v LRM

- ▶ Koeficient determinace (*coefficient of determination, R-squared*)

$$R^2 = 1 - \frac{S_e}{S_t} = \frac{S_r}{S_t} = \frac{S_r/n}{S_t/n} = \frac{\text{ML-odhad vysvětleného rozptylu}}{\text{ML-odhad celkového rozptylu}}$$

se používá ke kvantifikaci poměrné části variability, kterou se LRM podařilo vysvětlit

- ▶ $R^2 \in [0, 1]$
- ▶ V LRM platí: R^2 = koeficient mnohonásobné korelace = korelační poměr
- ▶ Korigovaný koeficient determinace (*adjusted R-squared, R-bar-squared*)

$$\begin{aligned}\bar{R}^2 &= 1 - (1 - R^2) \frac{n - 1}{n - k} = \\ &= 1 - \frac{S_e / (n - k)}{S_t / (n - 1)} = 1 - \frac{s^2}{S_Y^2} = 1 - \frac{\text{odhad rozptylu chyb}}{\text{výběrový celkový rozptyl}}\end{aligned}$$

lze použít pro porovnání různých podmodelů LRM

Řešení LRM pomocí R

V R řeší LRM příkaz `lm` (*linear model*):

```
model <- lm (formule, data=tabulka)
```

Máme-li zvlášť vektor regresorů (x) a pozorování (Y), datovou tabulkou (*data frame*) vytvoříme příkazem: `tabulka <- data.frame (x, Y)`

Zápis tzv. *formule* pro některé regresní funkce:

$$Y = \beta_0 + \beta_1 x \quad Y \sim x, \text{ nebo } Y \sim 1 + x, \text{ absolutní člen je vkládán implicitně}$$

$$Y = \beta_1 x \quad Y \sim 0 + x$$

$$Y = \beta_0 + \beta_1 x + \beta_2 x^2 \quad Y \sim x + I(x^2)$$

$$Y = \beta_1 |x| \quad Y \sim 0 + I(\text{abs}(x))$$

$$Y = \beta_0 + \beta_1 e^x \quad Y \sim I(\text{exp}(x))$$

$$Y = \beta_0 + \beta_1 \ln x \quad Y \sim I(\log(x))$$

Detailní výsledky a další číselné charakteristiky získáme příkazem

```
vysledky <- summary (model),
```

příp. s parametrem `correlation=TRUE` pro výpočet výběrové korelační matice parametrů.

Veličiny v LRM pomocí R

$\hat{\beta}$	MNČ-odhad parametrů	<code>model\$coefficients</code> <code>coef(model)</code>
$(\hat{\beta}_j, \text{SD}(\hat{\beta}_j), T_j, p_j)$	odhad, směrodatné odchylky, testy významnosti, p-hodnoty	<code>vysledky\$coefficients</code> <code>coef(vysledky)</code>
\hat{Y}	aproximované hodnoty	<code>model\$fitted.values</code> <code>fitted.values(model)</code>
r	rezidua	<code>model\$residuals</code> <code>residuals(model)</code>
$n - k$	stupně volnosti	<code>model\$df.residual</code>
X	matice plánu	<code>model.matrix(model)</code>
s	odhad směrod. odchylky chyb	<code>vysledky\$sigma</code>
R^2	koeficient determinace	<code>vysledky\$r.squared</code>
\bar{R}^2	korigovaný koef. determinace	<code>vysledky\$adj.r.squared</code>
$(F, k - 1, n - k)$	celkový F-test	<code>vysledky\$fstatistic</code>
$(k, n - k, k)$	stupně volnosti	<code>vysledky\$df</code>
$R(\hat{\beta})$	korelační matice pro $\hat{\beta}$	<code>vysledky\$correlation</code>

Grafy regresních funkcí v R

Připravíme souřadnicový systém vhodných rozměrů (první dva vektory min–max), do nějž zatím nic kreslit nebudeme (`type="n"`), přidáme popisky:

```
plot (c(0,70), c(-5,60), type="n", xlab="osa x", ylab="osa y")
```

Pomocí bodů vykreslíme data z tabulky, tzn. (x, Y) . První dva parametry jsou vektory x -ových a y -ových souřadnic, následují grafické parametry:

```
points (tabulka$x, tabulka$Y, col=4, pch=24, lwd=1.5, cex=1.0)
```

Zvolíme si dostatečně hustou síť x -ových souřadnic (x_*):

```
xx <- seq (0, 70, by=0.1)
```

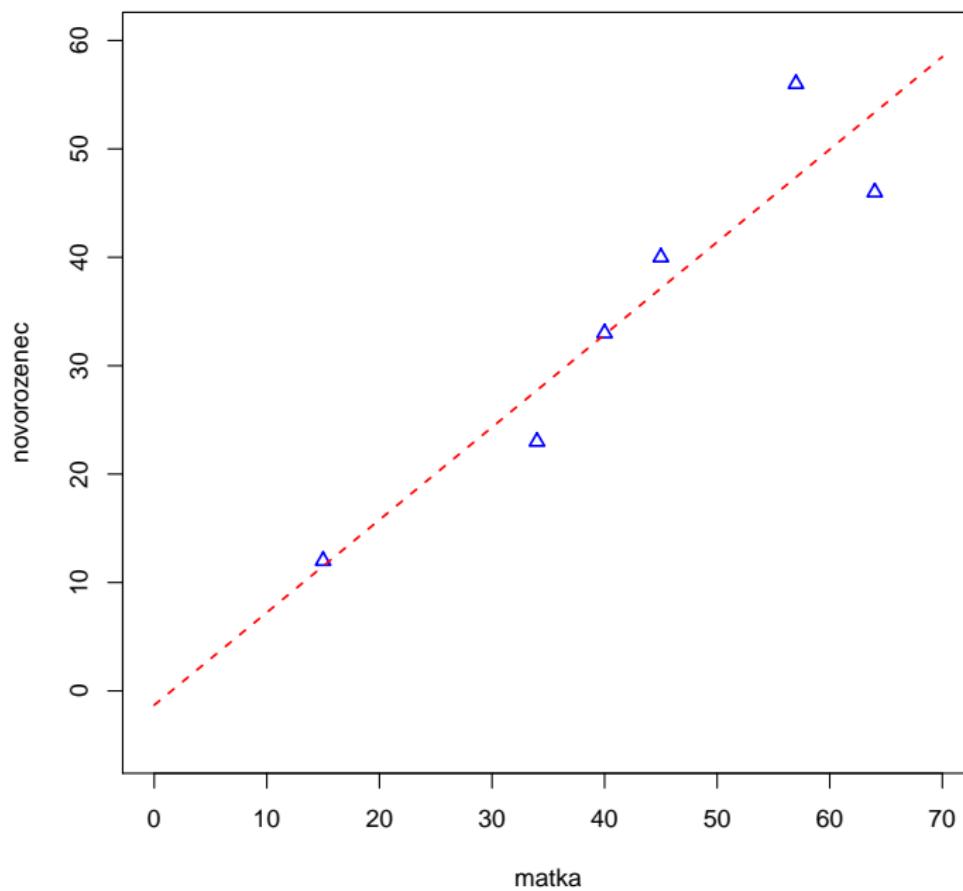
Dopočítáme k nim odpovídající y -ové souřadnice, tzn. \widehat{Y}_* :

```
YY <- predict (model, data.frame (x=xx))
```

Vykreslíme graf funkce jako křivku (x_*, \widehat{Y}_*) , podobně jako body:

```
lines (xx, YY, col=2, lwd=1.5, lty=2)
```

Obrázek můžeme uložit mj. příkazem `dev.copy2pdf(file="obrazek.pdf")`



LRM – příklady (1)

Datové soubory k následujícím příkladům jsou dostupné na serveru **bart** v adresáři **/erko/M5120/data**, odkud si je můžete zkopírovat. Pro jednotlivé soubory postupně navrhнete několik různých regresních modelů, spočítejte odhadы параметрů a další číselné charakteristiky, a modely porovnejte. Vykreslete do jednoho obrázku data i grafy spočítaných regresních funkcí. Později přidejte testování významnosti modelu (F -test) a testy významnosti parametrů (t -testy).

- 31.** Datový soubor **C3H603.txt**. Pomocí (obecné) regresní přímky spočítejte MNČ-odhadы vektoru parametrů $\hat{\beta}$, approximace \hat{Y} , reziduální součty čtverců S_e a s^2 v LRM ($Y, X\beta, \sigma^2 I$) pro data

x	40	64	34	15	57	45
Y	33	46	23	12	56	40

Jedná se o měření závislosti množství kyseliny mléčné ve 100 ml krve u matky-provorodičky, x , a jejího novorozence, Y . Obě veličiny jsou uváděny jako hmotnost v mg.

LRM – příklady (2)

- 32.** Datový soubor **roztažnost.txt**. Pomocí regresní přímky procházející počátkem spočítejte MNČ-odhad vektoru parametrů $\hat{\beta}$, approximace \hat{Y} , reziduální součty čtverců S_e a s^2 v LRM $(Y, X\beta, \sigma^2 I)$ pro data

x	10	20	30	40	50	60
Y	0.18	0.35	0.48	0.65	0.84	0.97

Jedná se o měření koeficientu teplotní délkové roztažnosti měděné trubky. Teplotní rozdíl od 20°C je x , prodloužení tyče je měřená veličina Y .

- 33.** Datový soubor **palivo.txt**. Pomocí (obecné) regresní paraboly spočítejte MNČ-odhad vektoru parametrů $\hat{\beta}$, approximace \hat{Y} , reziduální součty čtverců S_e a s^2 v LRM $(Y, X\beta, \sigma^2 I)$ pro data

x	40	50	60	70	80	90	100
Y	6.1	5.8	6.0	6.5	6.8	8.1	10.0

Jedná se o měření závislosti spotřeby paliva, Y v l/100 km motorového vozidla na rychlosti, x v km/h, při zařazeném stejném rychlostním stupni.

LRM – příklady (3)

- 34.** `carb_dio.tab`: Zkoumejte závislost koncentrace CO₂ v atmosféře v letech 1764–1995 pomocí regresní funkce tvaru vhodného polynomu a exponenciální funkce. Predikujte hodnoty pro 21. století.
- 35.** `carbon_e.tab`: Zkoumejte závislost uhlíkových emisí v letech 1950–1995 pomocí regresní funkce tvaru vhodného polynomu. Predikujte hodnoty pro 21. století.
- 36.** `globtemp.txt`: Zkoumejte závislost průměrné teploty v letech 1866–1996 pomocí regresní funkce tvaru vhodného polynomu. Predikujte hodnoty pro 21. století.
- 37.** `oil_prod.txt`: Zkoumejte závislost objemu vytěžené ropy v letech 1880–1988 pomocí regresní funkce tvaru vhodného polynomu a exponenciální funkce. Predikujte hodnoty pro 21. století.
- 38.** `population.txt`: Zkoumejte závislost velikosti populace na Zemi na čase pomocí regresní funkce tvaru vhodného polynomu a exponenciální funkce. Predikujte hodnoty pro 21. století.

LRM – příklady (4)

U vícerozměrných dat dále spočítejte výběrové korelační koeficienty a výběrové parciální korelační koeficienty. Obdržené hodnoty interpretujte.

- 39.** `beh.txt`: Příklad na vícerozměrnou regresi (maratonské běžkyně, 1977). Pomocí regresních přímek zkoumejte závislosti mezi třemi veličinami: rychlosť běhu, koroková frekvence, délka kroku.
- 40.** `deti.txt`: Příklad na vícerozměrnou regresi. Pomocí regresních přímek zkoumejte závislosti mezi třemi veličinami: hmotností dítěte, věkem a počtem bodů z diktátu.
- 41.** `domacnosti1957.txt`: Příklad na vícerozměrnou regresi (ČSR, 1957). Pomocí regresních přímek zkoumejte závislosti mezi třemi veličinami: počtem členů domácnosti, příjmy a výdaji.
- 42.** `enrollment.txt`: Příklad na vícerozměrnou regresi (VŠ v USA). Pomocí regresních přímek zkoumejte závislosti mezi veličinami: počet přihlášek na vysokou školu (ROLL), míra nezaměstnanosti (UNEM), počet absolventů střední školy (HGRAD) a průměrný příjem (INC).

Rozdělení pravděpodobnosti v LRM

- ▶ máme bodové odhady $\hat{\beta}$, chceme intervalové odhady a testování hypotéz
- ▶ teorie klasického LRM předpokládá $\epsilon \sim N(\mathbf{0}, \sigma^2 I_n)$
- ▶ Potom máme: $\mathbf{Y} \sim N(\mathbf{X}\beta, \sigma^2 I_n)$
- ▶ MNČ-odhad $\hat{\beta}$ vektoru parametrů je nestranný, $\hat{\beta} \sim N(\beta, \sigma^2 (\mathbf{X}'\mathbf{X})^{-1})$
- ▶ s^2 je nestranným odhadem rozptylu náhodných chyb, $E(s^2) = \sigma^2$
- ▶ $\frac{S_e}{\sigma^2} \sim \chi^2(n - k)$
- ▶ náhodné veličiny $\hat{\beta}$ a s^2 jsou stochasticky nezávislé
- ▶ $T = \frac{c' \hat{\beta} - c' \beta^0}{s \sqrt{c' (\mathbf{X}'\mathbf{X})^{-1} c}} \sim t(n - k)$ $(c \in \mathbb{R}^k)$
- ▶ $F = \frac{(\hat{\beta}^* - \beta^{*0})' W^{-1} (\hat{\beta}^* - \beta^{*0})}{s^2 m} \sim F(m, n - k)$
- β^* je subvektor o m složkách
- W je tomuto subvektoru odpovídající blok $m \times m$ matice $(\mathbf{X}'\mathbf{X})^{-1}$.
- horní index 0 značí zvolený číselný vektor, např. při testování významnosti dosazujeme $\beta^0 = (0, \dots, 0_k)',$ resp. $\beta^{*0} = (0, \dots, 0_m)'$

Testy významnosti v LRM

Test významnosti koeficientu β_i , tj. test $H_0: \beta_i = 0$ proti $H_1: \beta_i \neq 0$:

- ▶ v T volíme $c = e_i$ (i -tý jednotkový vektor), $\beta^0 = \mathbf{0}$
- ▶ $T_i = \frac{\hat{\beta}_i - 0}{s \sqrt{v_{i,i}}} \sim t(n - k)$, $v_{i,i} = \{(X'X)^{-1}\}_{i,i}$

Test významnosti modelu, $H_0: (\beta_1, \dots, \beta_p) = \mathbf{0}$ proti $H_1: \exists i > 0: \beta_i \neq 0$:

- ▶ v F volíme $\beta^* = (\beta_1, \dots, \beta_p)$, $m = k - 1$, $\beta^{*0} = (0, \dots, 0_p)$
- ▶ $F = \frac{n - k}{k - 1} \frac{S_r}{S_e} = \frac{n - k}{k - 1} \left(\frac{S_t}{S_e} - 1 \right) \sim F(k - 1, n - k)$

Obecné testy parametrů v LRM

Test lineární kombinace koeficientů $H_0: \mathbf{c}'\hat{\boldsymbol{\beta}} = \mathbf{c}'\boldsymbol{\beta}^0$ proti $H_1: \mathbf{c}'\hat{\boldsymbol{\beta}} \neq \mathbf{c}'\boldsymbol{\beta}^0$:

- ▶ $\mathbf{c} \in \mathbb{R}^k$ volíme podle požadované lineární kombinace
- ▶ $\boldsymbol{\beta}^0$ volíme tak, aby $\mathbf{c}'\boldsymbol{\beta}^0 \in \mathbb{R}$ byla testovaná hodnota
- ▶
$$T = \frac{\mathbf{c}'\hat{\boldsymbol{\beta}} - \mathbf{c}'\boldsymbol{\beta}^0}{s \sqrt{\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}}} \sim t(n-k)$$
- ▶ Příklad (parabola) • $\beta_0 + \beta_1 = 1?$ ⇒ volíme $\mathbf{c} = (1, 1, 0)', \mathbf{c}'\boldsymbol{\beta}^0 = 1$
- ▶ Příklad (přímka) • $2\beta_0 - 3\beta_1 = 10?$ ⇒ volíme $\mathbf{c} = (2, 3)', \mathbf{c}'\boldsymbol{\beta}^0 = 10$

Vektorový test koeficientů $H_0: \hat{\boldsymbol{\beta}}^* = \boldsymbol{\beta}^{*0}$ proti $H_1: \hat{\boldsymbol{\beta}}^* \neq \boldsymbol{\beta}^{*0}$:

- ▶ testujeme subvektor $\boldsymbol{\beta}^*$ o m složkách ($m \leq k$)
- ▶
$$F = \frac{\left(\hat{\boldsymbol{\beta}}^* - \boldsymbol{\beta}^{*0}\right)' W^{-1} \left(\hat{\boldsymbol{\beta}}^* - \boldsymbol{\beta}^{*0}\right)}{s^2 m} \sim F(m, n-k)$$
- ▶ W je testovanému subvektoru odpovídající blok $m \times m$ matice $(\mathbf{X}'\mathbf{X})^{-1}$
- ▶ Příklad • $(\beta_0, \beta_2)' = (0, 0)'$?
- ▶ Příklad • $(\beta_0, \beta_1)' = (0, 1)'$?

Korelační koeficient

Korelační koeficient (Pearsonův) R_{XY} :

- ▶ $R_{XY} = \frac{C(X, Y)}{\sqrt{D(X)} \sqrt{D(Y)}}$
- ▶ $R_{XY} \in [-1; 1]$
- ▶ je mírou lineární závislosti náhodných veličin X, Y (s kladnými rozptyly)
- ▶ Kovariance: $C(X, Y) = E [X - E(X)] [Y - E(Y)]$

Pro normálně rozdělené náhodné veličiny lze interpretovat pomocí LRM s regresní funkcí $\hat{Y} = \beta_0 + \beta_1 X$:

- ▶ $R_{XY} = 1 \Rightarrow$ pozitivní lineární závislost, $\beta_1 > 0$ je významný
- ▶ $R_{XY} = -1 \Rightarrow$ negativní lineární závislost, $\beta_1 < 0$ je významný
- ▶ $R_{XY} = 0 \Rightarrow$ lineární nezávislost, β_1 není významný

Obecně platí implikace: X, Y stochasticky nezávislé $\Rightarrow R_{XY} = 0$ (nezávislost \Rightarrow nekorelovanost)

Pro normálně rozdělení náhodně veličiny platí ekvivalence (nezávislost = nekorelovanost)

Výběrový korelační koeficient

Výběrový korelační koeficient r_{XY} :

► je empirickou analogií korelačního koeficientu R_{XY}

► pro náhodný výběr $((X_1, Y_1)', \dots, (X_n, Y_n)')$

$$r_{XY} = \frac{S_{XY}}{S_X S_Y}$$

► Výběrový rozptyl: $S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n-1} \left(\sum_{i=1}^n X_i^2 - n\bar{X}^2 \right)$

► Výběrová kovariance:

$$S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) = \frac{1}{n-1} (\sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y})$$

► Testy pro normálně rozdělené náhodné veličiny:

► **Test nezávislosti** $H_0: R_{XY} = 0$ proti $H_1: R_{XY} \neq 0$:

$$T = \frac{r_{XY}}{\sqrt{1 - r_{XY}^2}} \sqrt{n-2} \sim t(n-2)$$

► Test $H_0: R_{XY} = R_0$ proti $H_1: R_{XY} \neq R_0$ (tzv. Z-transformace):

$$U = \underbrace{\frac{1}{2} \ln \frac{1+r_{XY}}{1-r_{XY}}}_{Z} - \frac{1}{2} \ln \frac{1+R_0}{1-R_0} - \frac{R_0}{2(n-1)} \sqrt{n-3} \sim N(0, 1)$$

Výběrový koeficient mnohonásobné korelace

Výběrový koeficient mnohonásobné korelace $r_{Y \cdot X}$:

- ▶ $r_{Y \cdot X}^2 = R_{YX} R_{XX}^{-1} R_{XY}$
- ▶ je empirickou analogií koeficientu mnohonásobné korelace $R_{Y \cdot X}$
- ▶ $r_{Y \cdot X} \approx R_{Y \cdot X} = R(Y, \hat{Y})$
- ▶ $R_{Y \cdot X} \in [0; 1]$
- ▶ Koeficient determinace: $R^2 = r_{Y \cdot X}^2$
- ▶ pro náhodný výběr $((Y_1, X_1)', \dots, (Y_n, X_n)')$ z $(k+1)$ -rozměrného rozdělení
- ▶ Test pro normálně rozdělené náhodné veličiny $H_0: R_{Y \cdot X} = 0$ proti $H_1: R_{Y \cdot X} \neq 0$, tj. že Y nezávisí na komplexu náhodných veličin X :

$$F = \frac{n - k - 1}{k} \frac{r_{Y \cdot X}^2}{1 - r_{Y \cdot X}^2} \sim F(k, n - k - 1)$$

Výběrový koeficient parciální korelace

Výběrový koeficient parciální korelace $r_{Y,Z \cdot X}$:

- ▶
$$r_{Y,Z \cdot X} = \frac{r_{YZ} - R_{YX}R_{XX}^{-1}R_{XZ}}{\sqrt{(1 - R_{YX}R_{XX}^{-1}R_{XY})(1 - R_{ZX}R_{XX}^{-1}R_{XZ})}}$$
- ▶ je empirickou analogií parciálního korelačního koeficientu $R_{Y,Z \cdot X}$
- ▶ $r_{Y,Z \cdot X} \approx R_{Y,Z \cdot X} = R(Y - \hat{Y}, Z - \hat{Z})$
- ▶ $R_{Y,Z \cdot X} \in [-1; 1]$
- ▶ pro náhodný výběr $((Y_1, X_1, Z_1)', \dots, (Y_n, X_n, Z_n)')$ z $(k+2)$ -rozměrného rozdělení
- ▶ Test pro normálně rozdělené náhodné veličiny $H_0: R_{Y,Z \cdot X} = 0$ proti $H_1: R_{Y,Z \cdot X} \neq 0$, tj. že Y, Z jsou nezávislé náhodné veličiny po odečtení (lineárního) vlivu komplexu náhodných veličin X :

$$T = \frac{r_{Y,Z \cdot X}}{\sqrt{1 - r_{Y,Z \cdot X}^2}} \sim t(n - k - 2)$$

Výběrové korelační koeficienty v R

- ▶ předpokládáme, že v proměnných X , Y , Z máme realizace náhodného výběru
- ▶ `cor (X, Y)` \Rightarrow výběrový korelační koeficient r_{XY}
- ▶ Výběrový koeficient mnohonásobné korelace $r_{Z \cdot (X,Y)'}^*$
 - ▶ `mZ <- lm (1 + X + Y)` \Rightarrow LRM na proměnných X, Y
 - ▶ `Zh <- mZ$fitted.values` \Rightarrow $\hat{Z} = \hat{\beta}_0 + \hat{\beta}_X X + \hat{\beta}_Y Y$
 - ▶ `cor (Z, Zh)` $\Rightarrow r_{Z \cdot (X,Y)'} = R(Z, \hat{Z})$
- ▶ Výběrový koeficient parciální korelace $r_{Y,Z \cdot X}$
 - ▶ `mY <- lm (1 + X)` \Rightarrow LRM na proměnné X
 - ▶ `mZ <- lm (1 + X)` \Rightarrow LRM na proměnné X
 - ▶ `Yr <- mY$residuals` \Rightarrow rezidua $Y - \hat{Y} = Y - \hat{\beta}_0 - \hat{\beta}_X X$
 - ▶ `Zr <- mZ$residuals` \Rightarrow rezidua $Z - \hat{Z} = Z - \hat{\alpha}_0 - \hat{\alpha}_Z X$
 - ▶ `cor (Yr, Zr)` $\Rightarrow r_{Y,Z \cdot X} = R(Y - \hat{Y}, Z - \hat{Z})$