

# M5VM05 Statistické modelování

## 6. Ověřování předpokladů v klasickém modelu lineární regrese – II

Jan Koláček (kolacek@math.muni.cz)

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



**Multikolinearitou** se rozumí vzájemná lineární závislost vysvětlujících proměnných. Přesnou multikolinearitou se rozumí případ, kdy jednotlivé sloupce  $\mathbf{x}_j$ ,  $j = 1, \dots, k$  matice plánu  $\mathbf{X}$  jsou lineárně závislé, takže pro aspoň jednu nenulovou konstantu  $c_j$  platí

$$c_1 \mathbf{x}_1 + \dots + c_k \mathbf{x}_k = \mathbf{0}.$$

V praxi bychom se s tímto případem neměli setkávat, neboť při rozumně sestaveném regresním modelu využijeme lineární kombinaci a zmenšíme počet vysvětlujících proměnných. Podobně nereálný je v praxi případ ortogonálních vysvětlujících proměnných, kdy matice  $\mathbf{X}$  je ortogonální a platí, že  $\mathbf{X}'\mathbf{X} = \mathbf{I}_k$ . V praxi se tedy **multikolinearitou** rozumí případ, kdy **přibližně** platí rovnice vyjadřující lineární kombinaci vysvětlujících proměnných. V případě silné multikolinearity je determinant informační matice  $\mathbf{X}'\mathbf{X}$  blízký nule, nejmenší vlastní číslo je rovněž blízké nule a matice  $\mathbf{X}'\mathbf{X}$  je „skoro singulární“. O multikolinearitě svědčí i vysoké hodnoty poměru největšího a nejmenšího vlastního čísla.

# Důvody multikolinearity

- Multikolinearitu způsobuje regresní rovnice obsahující **nadbytečné** vysvětlující proměnné. Statistickými technikami můžeme přebytečné proměnné identifikovat a vyloučit z regresní rovnice.
- Multikolinearitu jen ztěží odstraníme v úlohách, kdy vzájemná spříženost hodnot vysvětlujících proměnných je způsobena neuvažovanými veličinami nebo **formou statistického zjišťování**. Jde-li např. o údaje z časových řad, je podobný vývoj sledovaných veličin dostatečným důvodem vzniku multikolinearity. Vzhledem k tomu, že multikolinearitu hodnotíme výhradně na základě určitého souboru pozorování, stačí nesprávný výběr kombinací hodnot vysvětlujících proměnných, nerepresentujících obor možných hodnot, k existenci významné multikolinearity.
- Závažným důvodem multikolinearity je **skutečný vztah** vysvětlujících proměnných v rámci sledovaného jevu, procesu nebo systému. V tomto případě je třeba využít všechny informace nevýběrového charakteru k zlepšení kvality regresních odhadů.

# Důsledky multikolinearity

V případě přesné multikolinearity je matice  $\mathbf{X}'\mathbf{X}$  singulární a běžnou inverzí nepořídíme odhad neznámých parametrů  $\beta$  metodou nejmenších čtverců. Pro přibližnou multikolinearitu jsme sice schopni matici  $\mathbf{X}'\mathbf{X}$  invertovat, ale kvalita pořízených odhadů je poměrně nízká.

Snížení kvality se projeví

- v kovarianční matici  $var(\hat{\beta}) = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$
- v přesnosti prováděných výpočtů

neboť důsledkem vysokých rozptylů odhadů jsou příliš široké intervaly spolehlivosti, a tedy malá přesnost odhadu.

Logickým důsledkem multikolinearity je obtížné vyjádření individuálního vlivu jednotlivých vysvětlujících proměnných. Projeví se to nízkými hodnotami testových kritérií v  $t$ -testech nedovolujícími potvrdit závažnost jednotlivých regresorů v regresní funkci. Závažným důsledkem je značná výpočetní nespolehlivost a nestabilní hodnoty regresních odhadů. Stačí malý zásah do statistických údajů a výsledné odhady jsou odlišné.

# VIF – Variance Inflation Factors

Diagonální prvky matice  $(\mathbf{X}'\mathbf{X})^{-1}$ , tj.

$$\mathbf{a} = \text{diag}(\mathbf{X}'\mathbf{X})^{-1}$$

označované v literatuře jako **VIF – variance inflation factors** úzce souvisí s **vícenásobnými korelačními koeficienty**, vyjadřující vztah  $j$ -té vysvětlující proměnné a lineární funkce ostatních vysvětlujících proměnných. Lze je zapsat jako

$$a_j = \frac{1}{(1 - r_j^2)\mathbf{x}_j'\mathbf{x}_j}$$

kde  $r_j = r_{x_j \cdot x_1 x_2 \dots x_{j-1} x_{j+1} \dots x_k}$  je koeficient mnohonásobné korelace.

Vysoký stupeň multikolinearity se projevuje vysokými hodnotami korelačních koeficientů  $r_j$ , ale i vysokými hodnotami některých jednoduchých korelačních koeficientů.

# Detekce multikolinearity

Testujeme hypotézu  $H_0 : \mathbf{R} = \mathbf{I}_k$  proti  $H_1 : \mathbf{R} \neq \mathbf{I}_k$ , kde  $\mathbf{R}$  je korelační matice proměnných. Platí-li nulová hypotéza, pak

$$K = - \left[ n - 1 - \frac{1}{6}(2k + 7) \right] \ln |\mathbf{R}| \sim \chi^2 \left( \frac{k(k-1)}{2} \right).$$

Hypotézu  $H_0$  tedy na hladině významnosti  $\alpha$  zamítáme, pokud  $K > \chi_{1-\alpha}^2 \left( \frac{k(k-1)}{2} \right)$ .

# Identifikace proměnných způsobujících multikolinearitu

Pro identifikaci proměnných způsobujících multikolinearitu se doporučují statistiky

$$F_j = \frac{n - k}{k - 1} (d_{jj} - 1),$$

kde  $d_{jj}$  jsou diagonální prvky matice  $\mathbf{D} = \mathbf{R}^{-1}$ . V případě, že proměnná  $X_j$  nezpůsobuje multikolinearitu, má veličina  $F_j$  Fisherovo – Snedecorovo rozdělení  $F(k - 1, n - k)$ .

# Odstranění multikolinearity

Do modelu zařadíme jen ty regresory, které významně přispívají ke zlepšení kvality odhadu  $\beta$ . K výběru nejlepší podmnožiny regresorů použijeme **metodu postupné regrese**.

## Algoritmus:

- 1 Spočteme korelační matici  $\mathbf{R}$  a provedeme test hypotézy  $H_0 : \mathbf{R} = \mathbf{I}_k$ . Je-li korelace prokázána, pokračujeme dalším krokem.
- 2 Spočteme korelační koeficienty  $r_{Y,X_1}, \dots, r_{Y,X_k}$  a vybereme ten regresor  $X_i$ , jehož  $r_{Y,X_i}$  je v absolutní hodnotě největší.
- 3 Sestavíme model  $Y = \beta_0 + \beta_1 X_i$  a odhadneme jeho parametry. Vypočteme hodnotu statistiky  $F = \frac{(n-2)s_Y^2}{s^2} = \frac{(n-2)ID}{1-ID}$ , kde  $ID$  značí index determinace. Pokud  $F > F_{1-\alpha}(1, n-2)$ , ponecháme regresor  $X_i$  v modelu.
- 4 Spočteme parciální korelační koeficienty  $r_{Y,X_1 \cdot X_i}, \dots, r_{Y,X_{i-1} \cdot X_i}, r_{Y,X_{i+1} \cdot X_i}, \dots, r_{Y,X_k \cdot X_i}$  a vybereme ten regresor  $X_j$ , jehož  $r_{Y,X_j \cdot X_i}$  je v absolutní hodnotě největší.



# Odstranění multikolinearity

- 5 Sestavíme model  $Y = \beta_0 + \beta_1 X_i + \beta_2 X_j$  a odhadneme jeho parametry.  
Vypočteme hodnotu statistiky  $F = \frac{(n-3)\Delta ID}{1-ID}$ , kde  $\Delta ID$  je přírůstek indexu determinace při zařazení  $X_j$  do modelu a  $ID$  je index determinace pro model  $Y = \beta_0 + \beta_1 X_i + \beta_2 X_j$ . Pokud  $F > F_{1-\alpha}(2, n-3)$ , ponecháme regresor  $X_j$  v modelu.
- 6 Spočteme parciální korelační koeficienty  $r_{Y, X_1 \cdot (X_i, X_j)}, \dots, r_{Y, X_k \cdot (X_i, X_j)}$  a vybereme ten regresor  $X_l$ , jehož  $r_{Y, X_l \cdot (X_i, X_j)}$  je v absolutní hodnotě největší a tak pokračujeme dále.

## Zlepšování podmíněnosti matice $\mathbf{X}'\mathbf{X}$

- **Model standardizovaných proměnných.** Místo původních proměnných  $y_i$  a  $x_{ij}$  pracujeme s proměnnými ve tvaru

$$q_i = \frac{y_i - \bar{y}}{s_y}, \quad z_{ij} = \frac{x_{ij} - \bar{x}_j}{s_{x_j}},$$

kde  $s_y$  a  $s_{x_j}$  jsou směrodatné odchylky jednotlivých proměnných. Standardizací vysvětlujících proměnných dostáváme při použití metody nejmenších čtverců místo matice  $\mathbf{X}'\mathbf{X}$  korelační matici  $\mathbf{R} = \mathbf{Z}'\mathbf{Z}/n$ . Vektor  $\mathbf{Z}'\mathbf{q}/n$  obsahuje jednoduché korelační koeficienty  $r_{yx_j}$ . Standardizací proměnných se zmenšují zaokrouhlovací chyby a zlepšují se možnosti hodnocení individuálního vlivu proměnných pomocí regresních parametrů.

- **Model v kanonickém tvaru.** Místo modelu ve tvaru

$$\mathbf{Y} = \mathbf{X}'\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

pracujeme s modelem

$$\mathbf{Y} = \mathbf{U}'\boldsymbol{\gamma} + \boldsymbol{\varepsilon},$$

kde matice  $\mathbf{U} = \mathbf{XV}$ , vektor  $\boldsymbol{\gamma} = \mathbf{V}'\boldsymbol{\beta}$  a  $\mathbf{V}$  je matice standardizovaných vlastních vektorů odpovídajících vlastním číslům matice  $\mathbf{X}'\mathbf{X}$ . Odhady parametrů v kanonickém tvaru:

$$\hat{\boldsymbol{\gamma}} = \mathbf{L}^{-1}\mathbf{U}'\mathbf{Y},$$

kde  $\mathbf{L}$  je diagonální matice s vlastními čísly matice  $\mathbf{X}'\mathbf{X}$ . Kovarianční matice odhadů  $\text{var}(\hat{\boldsymbol{\gamma}}) = \sigma^2\mathbf{L}^{-1}$  ukazuje, že i v tomto případě jsou odhady nezávislé. Residuální součet čtverců se transformací nemění.

- **Hřebenová regrese** (ridge regression) – `lm.ridge` v balíku MASS

## Příklad

V souboru „vydaje.Rdata“ jsou uložena data o 20 náhodně vybraných domácnostech. Sloupce proměnné „domacnosti“ obsahují postupně tyto údaje: výdaje za potraviny a nápoje ( $Y$ ), počet členů domácnosti ( $X_1$ ), počet dětí ( $X_2$ ), průměrný věk výdělečně činných ( $X_3$ ) a příjem domácnosti ( $X_4$ ). Metodou postupné regrese zkonstruujte model s nejlepší podmíněností regresorů.

**Řešení** Uvažujme nejdřív model se všemi regresory. Spočtěme nejprve pro ilustraci  $\det((\mathbf{X}'\mathbf{X})^{-1}) = 4,65 \times 10^{-16}$ . Také hodnoty VIF jsou pro první dva regresory vysoké:

$$\begin{array}{cccc} \text{clenu} & \text{deti} & \text{vek} & \text{prijem} \\ \hline 21,23 & 16,18 & 1,31 & 3,4 \end{array}$$

Testujeme-li hypotézu  $H_0 : \mathbf{R} = \mathbf{I}_4$ , hodnota testové statistiky

$$K = - \left[ 19 - \frac{15}{6} \right] \ln |\mathbf{R}| = 64,94$$

výrazně převyšuje kritickou hodnotu  $\chi_{0,95}^2(6) = 12,59$ . Hypotézu  $H_0$  tedy na hladině významnosti 0,05 zamítáme.

Pro identifikaci proměnných způsobujících multikolinearitu můžeme spočítat dílčí statistiky  $F_j$

| clenu  | deti  | vek  | prijem |
|--------|-------|------|--------|
| 107,88 | 80,94 | 1,66 | 12,83  |

které porovnáme s kritickou hodnotou  $F_{0,95}(3, 16) = 3,24$ .

Postupná regrese

- 1 Spočteme korelační koeficienty  $r_{Y,X_1}, \dots, r_{Y,X_4} = (0,77; 0,67; 0,18; 0,73)$ . Vybereme regresor  $X_1$ , neboť jeho korelace je v absolutní hodnotě největší.
- 2 Sestavíme model  $Y = \beta_0 + \beta_1 X_1$ . Vypočteme hodnotu statistiky  $F = \frac{(n-2)ID}{1-ID} = \frac{18 \cdot 0,5897}{1-0,5897} = 25,87$ . Tato hodnota je větší než  $F_{0,95}(1, 18) = 4,41$ , takže regresor  $X_1$  ponecháme v modelu.
- 3 Spočteme parciální korelační koeficienty  $r_{Y,X_2 \cdot X_1}, r_{Y,X_3 \cdot X_1}, r_{Y,X_4 \cdot X_1} = (0,36; 0,499; 0,32)$ . Vybereme regresor  $X_3$ , jehož parciální korelační koeficient je v absolutní hodnotě největší.

- 4 Sestavíme model  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_3$ . Vypočteme hodnotu statistiky  $F = \frac{(n-3)\Delta ID}{1-ID} = \frac{17 \cdot 0,102}{1-0,69} = 5,64$ . Tato hodnota je větší než  $F_{0,95}(2, 17) = 3,59$ , tedy ponecháme regresor  $X_3$  v modelu.
- 5 Spočteme parciální korelační koeficienty  $r_{Y, X_2 \cdot (X_1, X_3)}, r_{Y, X_4 \cdot (X_1, X_3)} = (0,19; 0,17)$ . Vybereme regresor  $X_2$ , jehož parciální korelační koeficient je v absolutní hodnotě největší.
- 6 Sestavíme model  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_3 + \beta_3 X_2$ . Vypočteme hodnotu statistiky  $F = \frac{(n-4)\Delta ID}{1-ID} = \frac{16 \cdot 0,012}{1-0,704} = 0,63$ . Tato hodnota je menší než  $F_{0,95}(3, 16) = 3,24$ , a tedy regresor  $X_2$  již nezahrneme do modelu.

Výsledný model je tedy tvaru

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_3.$$

# Úlohy k procvičení

## Příklad 1

V souboru „*cement.RData*“ jsou uloženy údaje, které se týkají chemického složení portlandského cementu:

- $y$  množství tepla v kaloriích na gram cementu
- $x_1$  Tricalcium aluminate  $3\text{CaO} \cdot \text{Al}_2\text{O}_3$  v %
- $x_2$  Tricalcium silicate  $3\text{CaO} \cdot \text{SiO}_2$  v %
- $x_3$  Tetraaluminium ferrite  $4\text{CaO} \cdot \text{Al}_2\text{O}_3 \cdot \text{Fe}_2\text{O}_3$  v %
- $x_4$  Dicalcium silicate  $2\text{CaO} \cdot \text{SiO}_2$  v %

Testujte multikolinearitu v daném modelu. Metodou postupné regrese nalezněte vhodný model. Poté ověřte normalitu residuí.

[Multikolinearita se nezamítá, vhodný model:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_4$ , normalita residuí se nezamítá.]

# Úlohy k procvičení

## Příklad 2

V proměnné „*mtcars*“<sup>a</sup> jsou uložena data pro modelování závislosti spotřeby paliva osobních automobilů (proměnná *mpg*, počet mil/galon) na vlastnostech motoru, které jsou popsány následujícími proměnnými:

|             |  |
|-------------|--|
| <i>cyl</i>  | počet válců                              |
| <i>disp</i> | objem válců (kubické palce)              |
| <i>hp</i>   | výkon (počet koní)                       |
| <i>drat</i> | převodový poměr zadní nápravy            |
| <i>wt</i>   | hmotnost vozidla (kilolibry)             |
| <i>qsec</i> | zrychlení (počet sekund z 0 na 1/4 míle) |
| <i>vs</i>   | uspořádání válců (1 – „V“, 0 – za sebou) |
| <i>am</i>   | převodovka (0 – automat, 1 – manuál)     |
| <i>gear</i> | počet převodových stupňů                 |
| <i>carb</i> | počet karburátorů                        |

Testujte multikolinearitu v daném modelu. Metodou postupné regrese nalezněte vhodný model. Ověřte také normalitu residuí.

<sup>a</sup>datový soubor implementovaný v jazyce R



# Úlohy k procvičení

[Multikolarita se nezamítá, vhodný model:  $\text{mpg} = \beta_0 + \beta_1 \text{wt} + \beta_2 \text{cyl}$ , normalita residuí se nezamítá.]

## Příklad 3 (pro náročné)

*Naprogramujte funkci „multicol.R“, která pro zadaný model zjistí přítomnost multikolarity v datech. V případě, že je multikolarita přítomna, metodou postupné regrese nalezne vhodný model.*