

## M6120 – 9. CVIČENÍ : M6120cv09 (*Multikolinearita a korelovaná pozorování*)

### A. Multikolinearita a její zdroje.

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

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

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

$$\mathbf{X}'\mathbf{X} = \mathbf{I}_p, \quad k = p + 1, \quad \text{matice plánu } \mathbf{X}^* = (\mathbf{1}_n, \mathbf{X}).$$

**Multikolinearitou se 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".

**Důvody multikolinearity mohou být různé:**

- 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 spřaženosť hodnot vysvětlujících proměnných je způsobena neuvažovanými veličinami nebo **formou statistického zjištování**. 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, ne-reprezentujících 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.

### B. 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 (silnou) multikolinearitu** jsme sice schopni matici  $\mathbf{X}'\mathbf{X}$  invertovat, ale kvalita pořízených odhadů je poměrně nízká.

### Snížení kvality se projeví

- v kovarianční matici  $\text{var}(\hat{\beta})$  a
- v přesnosti prováděných výpočtů.

### Diagonální prvky matice

$$(\mathbf{X}'\mathbf{X})^{-1},$$

tj.

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

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

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

kde

$$r_j = r_{x_j.x_1x_2\dots x_{j-1}x_{j+1}\dots x_p}$$

je koeficient mnohonásobné korelace. Vysoký stupeň multikolinearity se projevuje vysokými hodnotami korelačních koeficientů  $r_j$  (blízkých 1), ale i vysokými hodnotami některých (nebo všech) jednoduchých korelačních koeficientů.

O multikolinearitě svědčí i **vysoké hodnoty poměru největšího a nejmenšího vlastního čísla**.

Důsledkem vysokých rozptylů odhadů jsou příliš dlouhé 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 testech  $t$ , nedovolujícími potvrdit závažnost jednotlivých regresorů v regresní funkci.

Některí autoři doporučují **testovat hodnotu determinantu korelační matice R** vysvětlujících proměnných pomocí veličiny

$$W = - \left[ n - 1 - \frac{1}{6}(2p + 7) \right] \ln |\mathbf{R}|,$$

která má při ortogonalitě proměnných rozdělení  $\chi^2$  s  $p(p - 1)/2$  stupni volnosti. **Jde o test hypotézy, že korelační matice je jednotková.**

Pro identifikaci proměnných způsobujících multikolinearitu se doporučují veličiny

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

kde  $d_{jj}$  jsou diagonální prvky matice

$$\mathbf{D} = \mathbf{R}^{-1}.$$

Veličiny  $F_j$  mají v případech, kdy proměnná  $x_j$  nezpůsobuje multikolinearitu, rozdělení  $F$  s  $p - 1$  a  $n - p$  stupni volnosti.

Poznamenejme, že přes značně nepříznivé důsledky se nemusí multikolinearita nepříznivě projevit na predikčních schopnostech regresního modelu.

Závažným důsledkem multikolinearity je značná výpočetní nespolehlivost a nestabilní hodnoty regresních odhadů. Stačí malý zásah do statistických údajů a výsledné odhady jsou odlišné.

### C. Zlepšování podmíněnosti matice $\mathbf{X}'\mathbf{X}$ transformací proměnných:

Poznamenejme, že  $\mathbf{X}$  je zde celá matice plánu.

**Model centrovaných proměnných.** Místo hodnot  $y_i$  a  $x_{ij}$ ,  $i = 1, \dots, n$ ,  $j = 1, \dots, p$ , používáme odchylky od aritmetických průměrů  $\bar{y}$  a  $\bar{x}_j$ . Není obtížné ukázat, že hlavní předností centrování proměnných je výpočetní zjednodušení. S výjimkou absolutního člena se odhady parametrů centrováním nezmění.

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

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

kde  $s_y$  a  $s_{x_j}$  jsou směrodatné odchylky jednotlivých proměnných. Standardizaci 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  $r_{yx_j}$ .

Standardizaci proměnných se zmenšují zaokrouhlovací chyby a zlepšují se možnosti hodnocení individuálního vlivu proměnných pomocí regresních parameterů (viz tzv. beta koeficienty).

### Model ortogonalizovaných vysvětlujících proměnných.

Pomocí **Grammova-Schmidtova ortogonalizačního postupu** a standardizací sloupcových vektorů získáme soustavu ortonormálních vektorů takových, že matice  $\mathbf{X}'\mathbf{X} = \mathbf{I}_k$ . Užitečným důsledkem ortogonalizace je nezávislost regresních odhadů, tj.

$$var(\hat{\boldsymbol{\beta}}) = \sigma^2 \mathbf{I}_k$$

a tím i dobrá interpretace výsledků.

**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

$$\mathbf{U} = \mathbf{X}\mathbf{V},$$

vektor

$$\boldsymbol{\gamma} = \mathbf{V}'\boldsymbol{\beta},$$

a  $\mathbf{V}$  je matice standardizovaných vlastních vektorů odpovídajících vlastním číslům matice  $\mathbf{X}'\mathbf{X}$ . Odhad parametrů modelu v kanonickém tvaru:

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

kde  $\mathbf{L}$  je diagonální matice s vlastními čísly matice  $\mathbf{X}'\mathbf{X}$ . Kovarianční matice odhadů

$$var(\mathbf{c}) = \sigma^2 \mathbf{L}^{-1}$$

ukazuje, že i v tomto případě jsou odhady nezávislé. Rozptyly odhadů závisí na velikosti vlastních čísel (čím větší je vlastní číslo, tím menší je rozptyl odhadu). Vztah mezi původními a transformovanými odhady je možné vyjádřit jako

$$\mathbf{c} = \mathbf{V}'\mathbf{b}.$$

Reziduální součet čtverců se transformací nemění.

## D. Hřebenová regrese.

Autoři hřebenové regrese vyšli ze skutečnosti, že při vysoké multikolinearitě jsou diagonální prvky matice  $(\mathbf{X}'\mathbf{X})^{-1}$  příliš velké ( $\mathbf{X}$  je zde celá matice plánu). Navrhli proto zkreslený odhad

$$\hat{\boldsymbol{\beta}}_H = (\mathbf{X}'\mathbf{X} + m\mathbf{I}_k)^{-1}\mathbf{X}'\mathbf{Y},$$

kde  $m$  je kladná konstanta. Pro  $m = 0$  je  $\hat{\boldsymbol{\beta}}_H = \hat{\boldsymbol{\beta}}$ . Zkreslení odhadu je

$$-m(\mathbf{X}'\mathbf{X} + m\mathbf{I}_k)^{-1}\boldsymbol{\beta}.$$

S růstem konstanty  $m$  se  $\hat{\boldsymbol{\beta}}_H$  blíží k nule.

Při užití metody hřebenové regrese se většinou vychází z modelu v kanonickém tvaru

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

Odhadem  $\hat{\boldsymbol{\gamma}}$  hřebenou regresí je

$$\hat{\boldsymbol{\gamma}}_H = \mathbf{c}_H = (\mathbf{L} + m\mathbf{I}_k)^{-1}\mathbf{U}'\mathbf{Y},$$

kde  $\mathbf{L}$  je diagonální matice s vlastními čísly matice  $\mathbf{X}'\mathbf{X}$  a  $\mathbf{U} = \mathbf{X}'\mathbf{V}$ .

Vztah mezi odhady metodou nejmenších čtverců a hřebenovými odhady je možno zapsat jako

$$\hat{\boldsymbol{\beta}}_H = \mathbf{V}\mathbf{D}\mathbf{V}'\hat{\boldsymbol{\beta}},$$

kde  $\mathbf{V}$  je matice vlastních vektorů odpovídajících  $\mathbf{X}'\mathbf{X}$ ,

$\mathbf{D}$  je diagonální matice s prvky  $\frac{\lambda_j}{\lambda_j + m}$  a

$\lambda_j$  jsou vlastní čísla matice  $\mathbf{X}'\mathbf{X}$ .

Mezi odhady v původním a kanonickém tvaru je vztah

$$\mathbf{c}_H = \mathbf{V}'\hat{\boldsymbol{\beta}}_H.$$

Nechceme-li zvyšovat všechny diagonální prvky matice  $\mathbf{X}'\mathbf{X}$  o stejnou konstantu ( $m$ ) máme možnost použít metodu **zobecněné hřebenové regrese**, lišící se pouze v tom, že diagonální prvky se zvyšují o kladné konstanty  $m_j$  a  $\boldsymbol{\gamma}$  se odhadujeme jako

$$c_{ZH} = (\mathbf{L} + \mathbf{M})^{-1} \mathbf{U}' \mathbf{Y},$$

kde  $\mathbf{M}$  je diagonální matice s  $m_j$  na diagonále. Vztah mezi  $\hat{\boldsymbol{\beta}}$  a  $\hat{\boldsymbol{\beta}}_{ZH}$  lze opět vyjádřit

$$\hat{\boldsymbol{\beta}}_{ZH} = \mathbf{V} \mathbf{D} \mathbf{V}' \hat{\boldsymbol{\beta}},$$

kde diagonální matice  $\mathbf{D}$  obsahuje prvky  $\frac{\lambda_j}{\lambda_j + m_j}$ .

**Problémem** zůstává **určení konstanty**  $m$ , popř. konstant  $m_j$ . Platí tato skutečnost: pro určité hodnoty  $m$  se systém stabilizuje a dostává charakter ortogonálního systému a každá úloha má svou optimální hodnotu  $m$ .

Při použití metody hřebenové regrese bývá zvykem sledovat tzv. **HŘEBENOVOU STOPU**, tj. vztah mezi hodnotou určitého parametru a velikostí konstanty  $m$ .

V poslední době se doporučuje (pro grafické znázornění) používat místo  $m_j$  konstantu  $m_1$  definovanou jako

$$m_1 = p - \sum_{j=1}^p \frac{\lambda_j}{\lambda_j + m_j}.$$

Výhodou  $m_1$  je okolnost, že pro  $m_j \rightarrow \infty$  se blíží k  $p$ . Tato skutečnost umožňuje udělat si lepší představu o stabilizaci regresních odhadů při zvyšování hodnot  $m_j$ .

### Některé výpočetní postupy používané v hřebenové regresi.

Při znalosti konstanty  $m$  (konstant  $m_j$ ) můžeme na základě odhadů  $c_j$ ,  $j = 1, \dots, p$ , pro model v kanonickém tvaru snadno určit hřebenové odhady jako

$$c_{j,H} = \frac{c_j}{1 + m/\lambda_j}.$$

Ve skutečnosti však konstatu  $m$  neznáme, proto v původní práci autoři metody doporučili po převedení modelu do kanonického tvaru odhadnout  $m$  jako

$$k\hat{\sigma}^2 / \sum_{j=1}^k c_j^2.$$

Tento odhad  $m$  je možno dosadit do předchozího vzorce, a tak dostat "první" hřebenový odhad  $c_H$ . V postupu je třeba pokračovat s tím, že se tak podaří celý systém stabilizovat. Později došlo k rozpracování metody hřebenové regrese a objevila se celá řada možností odhadu konstanty  $m$ . Uved'me aspoň některé z nich:

- (a)  $ps_\varepsilon^2 / \sum_{j=1}^p \hat{\beta}_j^2$ , kde  $\hat{\beta}_j$  jsou odhady metodou nejmenších čtverců modelu v původním tvaru a  $s_\varepsilon^2 = \frac{SSE}{n-p-1}$

- (b)  $ps_{\varepsilon}^2 / \sum_{j=1}^k \lambda_j c_j^2$ , kde  $c_j$  jsou odhadы parametrů modelu v kanonickém tvaru  $c = \mathbf{V}' \hat{\beta}$   
a  $\mathbf{V}$  je matice charakteristických vektorů matice  $\mathbf{X}'\mathbf{X}$ .

(c) Hledání optimální hodnoty  $m$  z rovnice  $s_{\varepsilon}^2 \sum_{j=1}^p \frac{\lambda_j}{\lambda_j + m} = m \sum_{j=1}^p \frac{c_j^2 \lambda_j^2}{\lambda_j + m^2}$

(d) Hledání optimální hodnoty  $m$  z rovnice  $p = \frac{m}{s_{\varepsilon}^2} \sum_{j=1}^p \frac{c_j^2 \lambda_j}{\lambda_j + m}$

LITERATURA: Hebák, P., Hustopecký, J.(1987) Vícerozměrné statistické metody s aplikacemi, Praha, SNTL, Alfa

### PŘÍKLAD 1: Chemické složení portlandského cementu

Portlandský cement je nejvíce používaným druhem cementu při výrobě betonu a malt. Obsahuje směs oxidů kovů alkalických zemin vápníku dále pak oxidy křemíku a hliníku.

Portlandský cement a podobné materiály jsou vyráběny pálením vápence (jako zdroje vápníku) s jílem nebo s pískem (zdroj křemíku), čímž vzniká slínka, ke kterému se v procesu mletí přidá sádrovec, jako regulátor tuhnutí. Výsledný prášek po smísení s vodou začne hydratovat a tím tuhne.

Portlandský cement byl poprvé vyroben ve Velké Británii na počátku 19. století a jeho název je odvozen od podobnosti s portlandským kamenem (stavební kámen), který se těží v Dorsetu na ostrově Isle of Portland, který leží v kanálu La Manche. Patent na tento cement získal britský zedník Joseph Aspdin v roce 1824.

Máme k dispozici údaje, které se týkají chemického složení portlandského cementu:

- $y$  množství tepla v kaloriích na gram cementu
- $x_1$  složka číslo 1 v % (Tricalcium aluminate  $3\text{CaO} \cdot \text{Al}_2\text{O}_3$ )
- $x_2$  složka číslo 2 v % (Tricalcium silicate  $3\text{CaO} \cdot \text{SiO}_2$ )
- $x_3$  složka číslo 3 v % (Tetracalcium alumino ferrite  $4\text{CaO} \cdot \text{Al}_2\text{O}_3 \cdot \text{Fe}_2\text{O}_3$ )
- $x_4$  složka číslo 4 v % (Dicalcium silicate  $2\text{CaO} \cdot \text{SiO}_2$ )

Jde o velmi známá tzv. **Haldova data**, která byla publikována již v roce 1932 v Industrial and Engineering Chemistry 24.

Literatura: Woods, H., Steinour, H. H. and Starke, H. R. (1932) Effect of composition of Portland cement on heat evolved during hardening. *Industrial Engineering and Chemistry*, 24, 1207–1214.

Tato data byla převzata několika dalšími autory monografií o regresi, protože velmi dobře dokumentují některé problémy související s uplatněním regresní metody.


```
> cement <- matrix(c(78.5, 7, 26, 6, 60, 74.3, 1, 29, 15, 52, 104.3, 11,
+      56, 8, 20, 87.6, 11, 31, 8, 47, 95.9, 7, 52, 6, 33, 109.2, 11, 55,
+      9, 22, 102.7, 3, 71, 17, 6, 72.5, 1, 31, 22, 44, 93.1, 2, 54, 18,
+      22, 115.9, 21, 47, 4, 26, 83.8, 1, 40, 23, 34, 113.3, 11, 66, 9,
+      12, 109.4, 10, 68, 8, 12), ncol = 5, byrow = TRUE)
> colnames(cement) <- c("y", "x1", "x2", "x3", "x4")
```

```
> data <- data.frame(cement)
> print(data)
```

	y	x1	x2	x3	x4
1	78.5	7	26	6	60
2	74.3	1	29	15	52
3	104.3	11	56	8	20
4	87.6	11	31	8	47
5	95.9	7	52	6	33
6	109.2	11	55	9	22
7	102.7	3	71	17	6
8	72.5	1	31	22	44
9	93.1	2	54	18	22
10	115.9	21	47	4	26
11	83.8	1	40	23	34
12	113.3	11	66	9	12
13	109.4	10	68	8	12

Data vykreslíme

```
> plot(data)
```



Obrázek 1: *Chemické složení portlandského cementu*

Předpokládejme model ve formě

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4$$

```
> model <- lm(y ~ x1 + x2 + x3 + x4, data)
> summary(model)

Call:
lm(formula = y ~ x1 + x2 + x3 + x4, data = data)

Residuals:
    Min      1Q  Median      3Q     Max 
-3.1750 -1.6709  0.2508  1.3783  3.9254 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 62.4054    70.0710   0.891   0.3991    
x1          1.5511    0.7448   2.083   0.0708 .  
x2          0.5102    0.7238   0.705   0.5009    
x3          0.1019    0.7547   0.135   0.8959    
x4         -0.1441    0.7091  -0.203   0.8441    
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.446 on 8 degrees of freedom
Multiple R-squared:  0.9824,    Adjusted R-squared:  0.9736 
F-statistic: 111.5 on 4 and 8 DF,  p-value: 4.756e-07
```

Všimněme si, že podle statistiky  $F$  zamítáme nulovou hypotézu

$$H_0 : (\beta_1, \beta_2, \beta_3, \beta_4)' = (0, 0, 0, 0)' \quad vs \quad H_1 : (\beta_1, \beta_2, \beta_3, \beta_4)' \neq (0, 0, 0, 0)'$$

a model vysvětuje 97,36% rozptylu (Adjusted R-squared). Přesto jednotlivé  $t$ -testy neoznačí ani jednu promennou jako statisticky významnou. Tento paradox bývá důsledkem korelovaných regresorů  $x_1, x_2, x_3, x_4$ . Proto spočítáme nejprve korelační matici, následně její inverzi a všimneme si diagonálních prvků. Ještě si všimneme, že stejně výsledky dostaneme pomocí funkce `vif()` z knihovny `car`. Pro názornost hodnoty VIF vykreslíme.

```
> print(Xcor <- cor(cement[, -1]))

      x1        x2        x3        x4
x1  1.0000000  0.2285795 -0.82413376 -0.24544511
x2  0.2285795  1.0000000 -0.13924238 -0.97295500
x3 -0.8241338 -0.1392424  1.00000000  0.02953700
x4 -0.2454451 -0.9729550  0.02953700  1.00000000

> print(Xcorinv <- solve(Xcor))

      x1        x2        x3        x4
x1 38.49621  94.1197  41.88410  99.7858
x2 94.11969 254.4232 105.09139 267.5394
x3 41.88410 105.0914 46.86839 111.1451
x4 99.78580 267.5394 111.14509 282.5129


> print(VIF <- diag(Xcorinv))
```

```
x1          x2          x3          x4
38.49621 254.42317 46.86839 282.51286
```

```
> library(car)
> vif(model)
```

```
x1          x2          x3          x4
38.49621 254.42317 46.86839 282.51286
```

```
> par(mar = c(2, 5, 0.5) + 0.05)
> plot((1:length(VIF)), VIF, type = "h", main = "Variance Inflation Factor")
```



Obrázek 2: VIF pro *Chemické složení portlandského cementu*

Všechny VIF značně přesahují hodnotu 10, uvedenou už jako příliš velkou.

Všimněme si dále vlastních čísel korelační maticy.


```
> X.eig <- eigen(Xcor)
> eigenval <- X.eig$values
> eigenvect <- X.eig$vectors
> print(conditionnumber <- max(eigenval)/min(eigenval))
```

```
[1] 1376.881
```

```
> print(conditionindex <- max(eigenval)/eigenval)
```

```
[1] 1.000000 1.418534 11.980870 1376.880621
```

```
> par(mar = c(2, 5, 0.5) + 0.05)
> plot((1:length(eigenval)), eigenval, type = "b", main = "Eigenvalue Spectrum")
```



Obrázek 3: Spektrální rozklad korelační matici dat *Chemické složení portlandského cementu*

Testujme hodnotu determinantu korelační matice  $\mathbf{R}$  vysvětlujících proměnných pomocí veličiny

$$W = - \left[ n - 1 - \frac{1}{6}(2p + 7) \right] \ln |\mathbf{R}|,$$

která má při ortogonalitě proměnných rozdělení  $\chi^2$  s  $p(p - 1)/2$  stupni volnosti. **Jde o test hypotézy, že korelační matice je jednotková.**

```
> n <- nrow(data)
> p <- 4
> const <- -(n - 1 - (2 * p + 7)/6)
> alpha <- 0.05
> print(W <- const * log(det(Xcor)))

[1] 65.00172

> dg <- p * (p - 1)/2
> print(chi2Kvantily <- qchisq(alpha, dg))

[1] 1.635383
```

Protože statistika  $W$  je větší než příslušný kvantil  $\chi^2$  rozdělení, považujeme multikolinearitu za prokázanou.

Pro identifikaci proměnných způsobujících multikolinearitu se doporučují veličiny

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

kde  $d_{jj}$  jsou VIF prvky, tj. diagonální prvky matice  $\mathbf{D} = \mathbf{R}^{-1}$ . Veličiny  $F_j$  mají v případech, kdy proměnná  $x_j$  nezpůsobuje multikolinearitu, rozdělení  $F$  s  $k - 1$  a  $n - p$  stupni volnosti.

```
> const <- (n - p)/(p - 1)
> print(Fj <- const * (VIF - 1))
```

x1	x2	x3	x4
112.4886	760.2695	137.6052	844.5386

```
> print(Fkvantily <- qf(alpha, p - 1, n - p))
```

```
[1] 0.1134778
```

Vidíme, že všechny hodnoty  $F_j$  jsou vysoko významné. Poněkud větší je vliv dvojice  $x_2$  a  $x_4$ .

## E. Autokorelace reziduí

V regresních modelech pro časové řady je třeba věnovat velkou pozornost problematice autokorelovaných reziduí. Ve většině případů se u časových řad s autokorelací reziduí setkáme, neboť hodnota pozorování v časovém okažiku  $t$  velmi pravděpodobně ovlivní následující hodnoty.

Pro testování autokorelace reziduí prvního řádu je používán Durbin–Watsonův test

### Durbin–Watsonův test autokorelace reziduí 1. řádu

**Durbin–Watsonova statistika** je definována vztahem

$$D = \frac{\sum_{i=2}^n (r_i - r_{i-1})^2}{\sum_{i=1}^n r_i^2}.$$

Protože platí  $(a - b)^2 \leq 2a^2 + 2b^2$ , dostáváme

$$D \leq \frac{2 \sum_{i=2}^n r_i^2 + 2 \sum_{i=2}^n r_{i-1}^2}{\sum_{i=1}^n r_i^2} \leq 4 \quad \Rightarrow \quad \boxed{0 \leq D \leq 4}.$$

Vzhledem k tomu, že  $Er = 0$ , bude pro větší hodnoty  $n$  platit

$$\sum_{i=2}^n r_i^2 \doteq \sum_{i=1}^n r_i^2 \doteq \sum_{i=1}^{n-1} r_{i+1}^2.$$

Označme výběrový autokorelační koeficient:

$$\hat{\rho}(1) = \frac{\widehat{E}(r_i r_{i+1})}{\sqrt{\widehat{D} r_i \widehat{D} r_{i+1}}} = \frac{\sum_{i=1}^{n-1} r_{i+1} r_i}{\sqrt{\sum_{i=1}^{n-1} r_i^2 \sum_{i=1}^{n-1} r_{i+1}^2}} \Rightarrow D \approx 2(1 - \hat{\rho}_1) \quad \text{nebo} \quad \hat{\rho}(1) \approx 1 - \frac{D}{2}.$$

Pokud budou **rezipua málo korelovaná**, hodnota  $D$  se bude pohybovat **kolem 2**.

**Kladná korelace** způsobí, že  $D \in (0, 2)$  a **záporná korelace** způsobí, že  $D \in (2, 4)$ .

**Přesné rozdělení statistiky  $D$**  závisí na tvaru matice plánu  $\mathbf{X}$ , proto jsou tabelovány intervaly  $d_L$  a  $d_U$ , ve kterých se nachází kritické hodnoty (pro různá  $n$ ,  $k$  a  $\alpha$ ).

n	Dolní a horní hranice Durbin-Watsonova testu na 5% hladině významnosti									
	k=1		k=2		k=3		k=4		k=5+	
	$d_L$	$d_U$	$d_L$	$d_U$	$d_L$	$d_U$	$d_L$	$d_U$	$d_L$	$d_U$
50	1.50	1.59	1.46	1.63	1.42	1.67	1.38	1.72	1.34	1.77
60	1.55	1.62	1.51	1.65	1.48	1.69	1.44	1.73	1.41	1.77
70	1.58	1.64	1.55	1.67	1.52	1.70	1.49	1.74	1.46	1.77
80	1.61	1.66	1.59	1.69	1.56	1.72	1.53	1.74	1.51	1.77
90	1.63	1.68	1.61	1.70	1.59	1.73	1.57	1.75	1.54	1.78
100+	1.65	1.69	1.63	1.72	1.61	1.74	1.59	1.76	1.57	1.78

kde  $k$  je počet nezávisle proměnných v regresní rovnici.

Pro rychlé posouzení autokorelace prvního řadu vystačíme s následující tabulkou:


Pokud hodnota Durbin-Watsonovy statistiky $D$ bude v mezích				
0 až $d_L$	$d_L$ až $d_U$	$d_U$ až $(4 - d_U)$	$(4 - d_U)$ až $(4 - d_L)$	$(4 - d_L)$ až 4
Zamítáme $H_0$ KLADNÁ autoko- relace	Ani nezamítáme ani nepřijímáme $H_0$	Nezamítáme nulovou hypotézu $H_0$	Ani nezamítáme ani nepřijímáme $H_0$	Zamítáme $H_0$ NEGATIVNÍ auto- korelace

V knihovně `lmtest` prostředí R je Durbin–Watsonův test uveden jako funkce `dwttest()`.

### PŘÍKLAD 1: Ztráty vyrobené vody v letech 1953–1983

Podle *Historické statistické ročenky* z roku 1985 se sledovaly ztráty vyrobné vody (zjištěné jako podíl mezi možstvím vyrobené a fakturované vody) jako funkci množství vyrobené vody.

```
> vyroba <- c(351, 359, 387, 422, 450, 482, 515, 547, 593, 620, 649, 669,
+    708, 766, 794, 832, 856, 919, 978, 1030, 1083, 1131, 1205, 1262,
+    1333, 1391, 1436, 1488, 1554, 1608, 1646)
> ztraty <- c(64, 68, 63, 72, 74, 74, 80, 88, 117, 122, 140, 135, 143,
+    152, 166, 161, 164, 198, 227, 231, 252, 261, 282, 284, 321, 324,
+    326, 341, 368, 389, 391)
> par(mar = c(5, 5, 1.5, 0.5) + 0.05)
> plot(ztraty ~ vyroba)
> abline(lm(ztraty ~ vyroba), col = "red")
```



Obrázek 4: Ztráty vyrobené vody v letech 1953–1983

```
> model <- lm(ztraty ~ vyroba)
> summary(model)

Call:
lm(formula = ztraty ~ vyroba)

Residuals:
    Min      1Q  Median      3Q     Max 
-19.084 -6.693  1.066  6.252 15.799 

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) -42.340155   4.109317 -10.30 3.34e-11 ***
vyroba       0.263346   0.004151  63.45 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 9.261 on 29 degrees of freedom
Multiple R-squared:  0.9928,    Adjusted R-squared:  0.9926 
F-statistic: 4025 on 1 and 29 DF,  p-value: < 2.2e-16
```

```
> library(lmtest)
> (DWtest <- dwtest(ztraty ~ vyroba, alternative = "two.sided"))

Durbin-Watson test


data: ztraty ~ vyroba
DW = 1.0819, p-value = 0.003179
alternative hypothesis: true autocorrelation is not 0
```

Protože p-hodnota je menší než 0,05, zamítáme nulovou hypotézu, že data nejsou korelovaná.

```

> n <- length(ztraty)
> x <- resid(model)[1:(n - 1)]
> y <- resid(model)[2:n]
> par(mfrow = c(1, 1), mar = c(2, 2, 1, 0) + 0.05)
> txt <- paste("D =", round(DWtest$statistic, 2), " rho1 =", round(1 -
+ 0.5 * DWtest$statistic, 2), " p-value =", round(DWtest$p.value,
+ 5))
> plot(x, y)
> abline(h = 0, col = "gray")
> abline(lm(y ~ x), col = "red", lwd = 2)
> mtext(txt)

```



Obrázek 5: Grafické testování autokorelace *Ztráty vyrobené vody v letech 1953–1983*

## F. Úkol: Canadian Women's Labour-Force Participation Data

Načtěte informační a datový soubor `women.inf` a `women.txt`. Jako nezávisle proměnnou uvažujte rok. Pro dvě časové řady [2] *Percent of adult women in the workforce* a [4] *Men's average weekly wages, in constant 1935 dollars and adjusted for current tax rates* nalezněte vhodnou trendovou funkci a následně provedte analýzu reziduí. Zaměřte se především na autokorelaci.