

M5120 – cvičení

Lineární regresní model

Ondřej Pokora (pokora@math.muni.cz)

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

(podzim 2015)



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 konstantním 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 ($Y, X\beta, \sigma^2 I$) plné hodnosti

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

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

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

Metoda nejmenších čtverců (MNČ)

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

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

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

$$X'X\beta = X'Y$$

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

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

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*)

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

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

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

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 aproximovaných 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

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

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

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 tabulku (*data frame*) vytvoříme příkazem: `tabulka <- data.frame (x, Y)`

Zápis tzv. *formule* pro některé regresní funkce:

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

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

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

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

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

$Y = \beta_0 + \beta_1 \ln x$ $Y \sim I(\text{log}(x))$

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-odhady parametrů	<code>model\$coefficients</code> <code>coef(model)</code>
$(\hat{\beta}_j, SD(\hat{\beta}_j), T_j, p_j)$	odhady, 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>
\hat{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. (\mathbf{x}, \mathbf{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 (\mathbf{x}_*) :

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


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

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

Vykreslíme graf funkce jako křivku $(\mathbf{x}_*, \widehat{\mathbf{Y}}_*)$, 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 v adresáři /Vyuka/R/M5120/data, odkud si je zkopírujete. Pro jednotlivé soubory řešte lineární regresní modely, spočítejte odhady parametrů 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).

Příklad 1 (Datový soubor C3H603.txt)

Pomocí regresní přímky (a regresní paraboly) spočítejte MNČ-odhady vektoru parametrů $\hat{\beta}$, aproximace \hat{Y} , reziduální součty čtverců S_e a s^2 v LRM ($Y, X\beta, \sigma^2 I$).

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

Tabulka uvádí výsledky 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)

Příklad 2 (Datový soubor roztaznost.txt)

Pomocí regresní přímky procházející počátkem spočítejte MNČ-odhady parametrů $\hat{\beta}$, aproximace \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 .

Příklad 3 (Datový soubor palivo.txt)

Pomocí (obecné) regresní paraboly spočítejte MNČ-odhady vektoru parametrů $\hat{\beta}$, aproximace \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)

Příklad 4 (`carb_dio.tab`)

Zkoumejte závislost koncentrace CO_2 v atmosféře v letech 1764–1995 pomocí regresní funkce tvaru vhodného polynomu a exponenciální funkce. Predikujte hodnoty pro 21. století.

Příklad 5 (`carbon_e.tab`)

Zkoumejte závislost uhlíkových emisí v letech 1950–1995 pomocí regresní funkce tvaru vhodného polynomu. Predikujte hodnoty pro 21. století.

Příklad 6 (`globtemp.txt`)

Zkoumejte závislost průměrné teploty v letech 1866–1996 pomocí regresní funkce tvaru vhodného polynomu. Predikujte hodnoty pro 21. století.

Příklad 7 (`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.

LRM – příklady (4)

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

Příklad 8 (population.txt)

Zkoumejte závislost velikosti populace na Zemi na čase pomocí regresní funkce tvaru vhodného polynomu a exponenciální funkce. Predikujte hodnoty pro 21. století.

Příklad 9 (beh.txt)

Příklad na vícerozměrnou regresi (maratonské běžkyně, 1977). Pomocí regresních přímk zkoumejte závislosti mezi třemi veličinami: rychlost běhu, koroková frekvence, délka kroku.

Příklad 10 (deti.txt)

Příklad na vícerozměrnou regresi. Pomocí regresních přímk zkoumejte závislosti mezi třemi veličinami: hmotností dítěte, věkem a počtem bodů z diktátu.

LRM – příklady (5)

Příklad 11 (domacnosti1957.txt)

Příklad na vícerozměrnou regresi (ČSR, 1957). Pomocí regresních přímek zkoumejte závislosti mezi třemi veličinami: počtem členů domácnosti, příjmy a výdaji.

Příklad 12 (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
- ▶ $\mathbf{T} = \frac{\mathbf{c}'\hat{\beta} - \mathbf{c}'\beta^0}{s \sqrt{\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}}} \sim t(n - k)$ ($\mathbf{c} \in \mathbb{R}^k$)
- ▶ $\mathbf{F} = \frac{(\hat{\beta}^* - \beta^{*0})' \mathbf{W}^{-1} (\hat{\beta}^* - \beta^{*0})}{s^2 m} \sim F(m, n - k)$
- β^* je subvektor o m složkách
- \mathbf{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 $\mathbf{c} = \mathbf{e}_i$ (i -tý jednotkový vektor), $\boldsymbol{\beta}^0 = \mathbf{0}$

► $T_i = \frac{\hat{\beta}_i - 0}{s \sqrt{v_{i,i}}} \sim t(n - k), \quad v_{i,i} = \{(\mathbf{X}'\mathbf{X})^{-1}\}_{i,i}$

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 $\boldsymbol{\beta}^* = (\beta_1, \dots, \beta_p)$, $m = k - 1$, $\boldsymbol{\beta}^{*0} = (0, \dots, 0_p)$

► $F = \frac{n - k}{k - 1} \cdot \frac{S_t}{S_r} \sim F(p, n - k) = F(k - 1, n - k)$

Obecné testy parametrů v LRM

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

- ▶ $c \in \mathbb{R}^k$ volíme podle požadované lineární kombinace
- ▶ β^0 volíme tak, aby $c'\beta^0 \in \mathbb{R}$ byla testovaná hodnota

$$\text{▶ } T = \frac{c'\hat{\beta} - c'\beta^0}{s \sqrt{c'(X'X)^{-1}c}} \sim t(n-k)$$

- ▶ Příklad (parabola) • $\beta_0 + \beta_1 = 1$? \Rightarrow volíme $c = (1, 1, 0)'$, $c'\beta^0 = 1$
- ▶ Příklad (přímka) • $2\beta_0 - 3\beta_1 = 10$? \Rightarrow volíme $c = (2, 3)'$, $c'\beta^0 = 10$

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

- ▶ testujeme subvektor β^* o m složkách ($m \leq k$)

$$\text{▶ } F = \frac{(\hat{\beta}^* - \beta^{*0})' W^{-1} (\hat{\beta}^* - \beta^{*0})}{s^2 m} \sim F(m, n-k)$$

- ▶ W je testovanému subvektoru odpovídající blok $m \times m$ matice $(X'X)^{-1}$
- ▶ Příklad • $(\beta_0, \beta_2)'$ = $(0, 0)'$?
- ▶ Příklad • $(\beta_0, \beta_1)'$ = $(0, 1)'$?

Korelační koeficient

Korelační koeficient (Pearsonův) R_{XY} :

$$\blacktriangleright R_{XY} = \frac{C(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}}$$

$$\blacktriangleright R_{XY} \in [-1; 1]$$

\blacktriangleright je mírou **lineární** závislosti náhodných veličin X, Y (s kladnými rozptyly)

$$\blacktriangleright \text{Kovariance: } C(X, Y) = E[X - E(X)][Y - E(Y)]$$

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

$\blacktriangleright R_{XY} = 1 \Rightarrow$ pozitivní lineární závislost, $\beta_1 > 0$ je významný

$\blacktriangleright R_{XY} = -1 \Rightarrow$ negativní lineární závislost, $\beta_1 < 0$ je významný

$\blacktriangleright R_{XY} = 0 \Rightarrow$ lineární nezávislost, β_1 není významný

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

Pro normálně rozdělené náhodné veličiny platí ekvivalence (nezávislost = nekorelovanost)

Výběrový korelační koeficient

Výběrový korelační koeficient r_{XY} :

- ▶ je empirickou analogií korelačního koeficientu R_{XY}
- ▶ pro náhodný výběr $((X_1, Y_1)', \dots, (X_n, Y_n)')$

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

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

- ▶ Výběrová kovariance:

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

- ▶ 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 $r_{Y \cdot X}$:

▶ $r_{Y \cdot X}^2 = \mathbf{R}_{YX} \mathbf{R}_{XX}^{-1} \mathbf{R}_{XY}$

▶ 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 $((Y_1, \mathbf{X}_1)', \dots, (Y_n, \mathbf{X}_n)')$ 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 \mathbf{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 $r_{Y,Z \cdot X}$:

$$\blacktriangleright r_{Y,Z \cdot X} = \frac{r_{YZ} - R_{YX}R_{XX}^{-1}R_{XZ}}{\sqrt{\left(1 - R_{YX}R_{XX}^{-1}R_{XY}\right) \left(1 - R_{ZX}R_{XX}^{-1}R_{XZ}\right)}}$$

▶ je empirickou analogií parciálního korelačního koeficientu $R_{Y,Z \cdot X}$

$$\blacktriangleright r_{Y,Z \cdot X} \approx R_{Y,Z \cdot X} = R(Y - \hat{Y}, Z - \hat{Z})$$

$$\blacktriangleright R_{Y,Z \cdot X} \in [-1; 1]$$

▶ pro náhodný výběr $((Y_1, \mathbf{X}_1, Z_1)', \dots, (Y_n, \mathbf{X}_n, Z_n)')$ 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 \mathbf{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)` $\Rightarrow r_{Y,Z \cdot X} = R(Y - \hat{Y}, Z - \hat{Z})$