

Bi7491 Regresní modelování

---

# Lineární regresní model I

## Definice a zadání

# Co byste po dnešní hodině měli vědět a umět?

- ➔ Vědět, jak se definuje lineární regresní model
- ➔ Vysvětlit předpoklady regresních modelů
- ➔ Umět použít v lineárním regresním modelu různé typy prediktorů
- ➔ Vědět, co je multikolinearita, jak ji zjistit a jak se s ní vypořádat

# Lineární regresní model I

**Definice lineárního regresního modelu**

# Vitamin D supplementation to prevent acute respiratory tract infections: systematic review and meta-analysis of individual participant data

Adrian R Martineau,<sup>1,2</sup> David A Jolliffe,<sup>1</sup> Richard L Hooper,<sup>1</sup> Lauren Greenberg,<sup>1</sup> John F Aloia,<sup>3</sup> Peter Bergman,<sup>4</sup> Gal Dubnov-Raz,<sup>5</sup> Susanna Esposito,<sup>6</sup> Davaasambuu Ganmaa,<sup>7</sup> Adit A Ginde,<sup>8</sup> Emma C Goodall,<sup>9</sup> Cameron C Grant,<sup>10</sup> Christopher J Griffiths,<sup>1,2,11</sup> Wim Janssens,<sup>12</sup> Ilkka Laaksi,<sup>13</sup> Semira Manaseki-Holland,<sup>14</sup> David Mauger,<sup>15</sup> David R Murdoch,<sup>16</sup> Rachel Neale,<sup>17</sup> Judy R Rees,<sup>18</sup> Steve Simpson,Jr<sup>19</sup> Iwona Stelmach,<sup>20</sup> Geeta Trilok Kumar,<sup>21</sup> Mitsuyoshi Urashima,<sup>22</sup> Carlos A Camargo Jr<sup>23</sup>

## WHAT IS ALREADY KNOWN ON THIS TOPIC

Randomised controlled trials of vitamin D supplementation for the prevention of acute respiratory tract infection have yielded conflicting results

Individual participant data (IPD) meta-analysis has the potential to identify factors that may explain this heterogeneity, but this has not previously been performed

## WHAT THIS STUDY ADDS

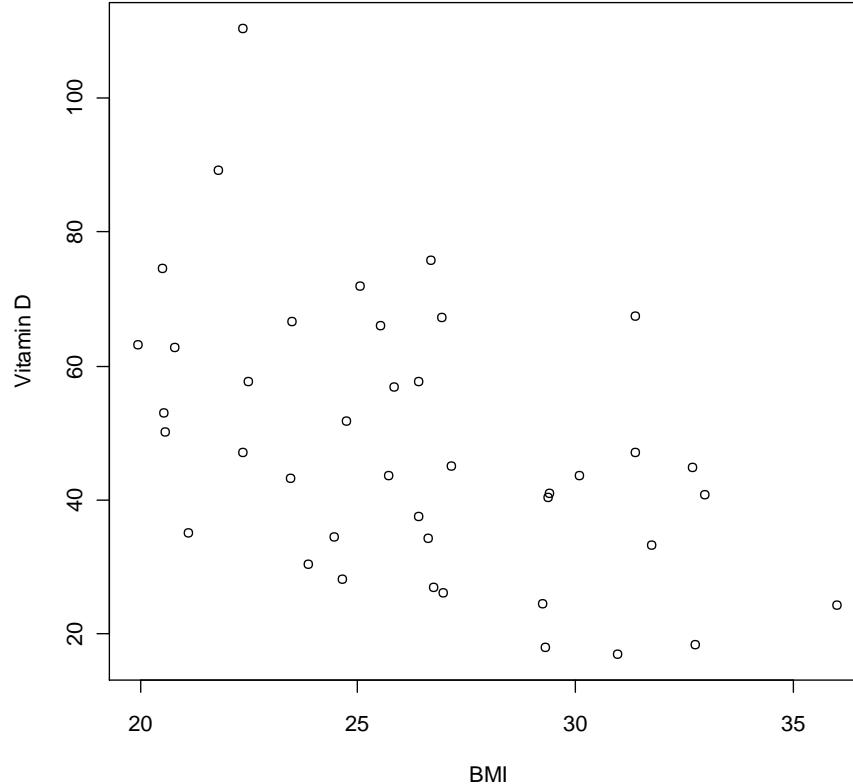
Meta-analysis of IPD from 10 933 participants in 25 randomised controlled trials showed an overall protective effect of vitamin D supplementation against acute respiratory tract infection (number needed to treat (NNT)=33)

Benefit was greater in those receiving daily or weekly vitamin D without additional bolus doses (NNT=20), and the protective effects against acute respiratory tract infection in this group were strongest in those with profound vitamin D deficiency at baseline (NNT=4)

These findings support the introduction of public health measures such as food fortification to improve vitamin D status, particularly in settings where profound vitamin D deficiency is common

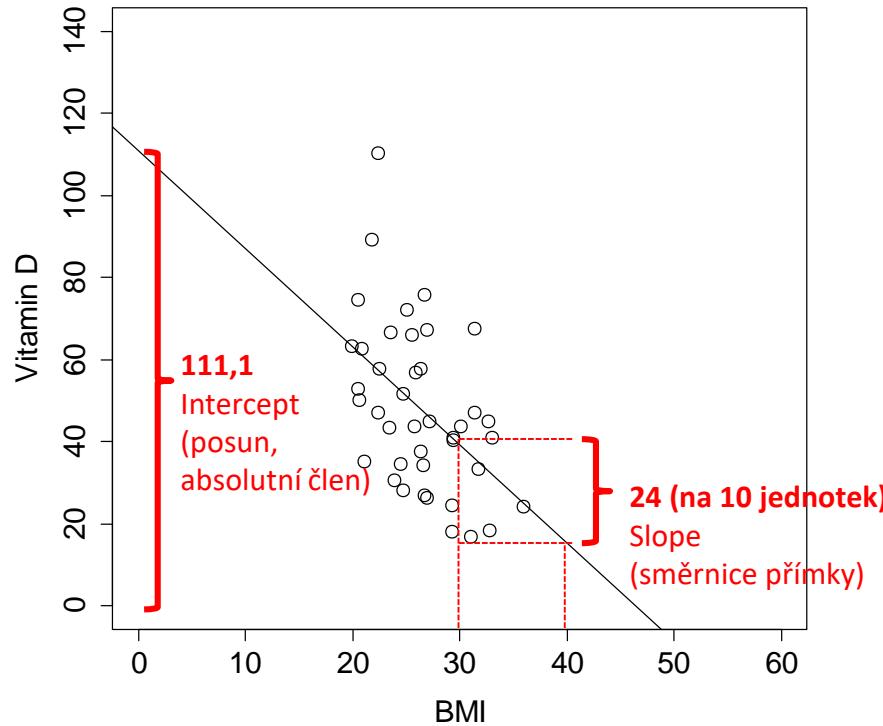
the **bmj** | BMJ 2017;356:i6583 | doi: 10.1136/bmj.i6583

# Jak popsát vztah mezi dvěma kvantitativními proměnnými?



intuitivně jsme schopni nakreslit přímku vedoucí mezi pozorováními...

# Jak popsát vztah mezi dvěma kvantitativními proměnnými?



Metoda nejmenších čtverců – minimalizuje vzdálenosti přímky od bodů

$$\text{koncentrace vitaminu D} = 111,1 - 2,4\text{BMI}$$

# Model s jednou spojitou proměnnou

$$Y_i \approx \beta_0 + \beta_1 x_i$$

$i = 1, \dots, n$

absolutní člen, posun

směrnice (sklon) regresní přímky

počet pozorování

proč tady není  $\equiv$  ??

# Lineární regresní model

## Stochastická složka

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad i = 1, \dots, n$$

Rezidua

Pro rezidua musí platit:

1. jsou **nesystematické**

$$E\varepsilon_i = 0$$

2. jsou **homogenní v rozptylu**

$$D\varepsilon_i = \sigma^2 > 0$$

3. jsou **nekorelované**

$$C(\varepsilon_i, \varepsilon_j) = 0, i \neq j$$

# Vícenásobná (víceprediktorová) regrese

Ize zapojit více vysvětlujících proměnných

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i$$

$$i = 1, \dots, n$$

Ize zapsat jako vztah pro střední hodnotu (a vynechat rezidua)

$$EY_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip}$$

$$i = 1, \dots, n$$

---

kde  $\beta_j$  jsou neznámé **parametry** ( $j = 0, \dots, p$ )

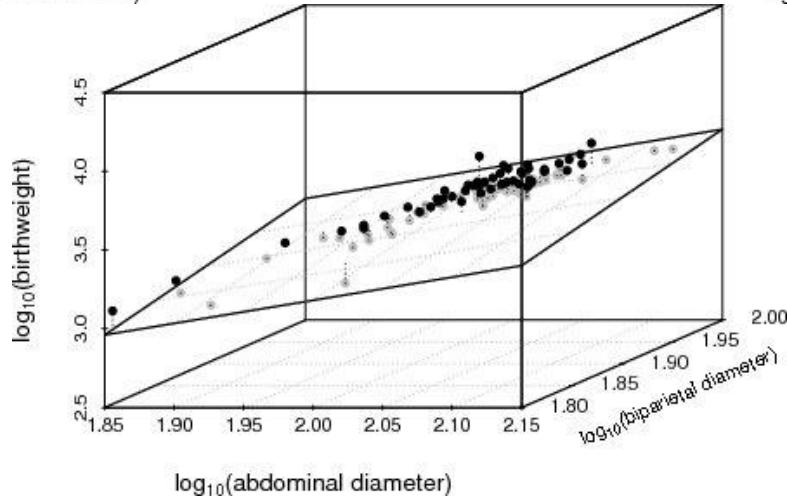
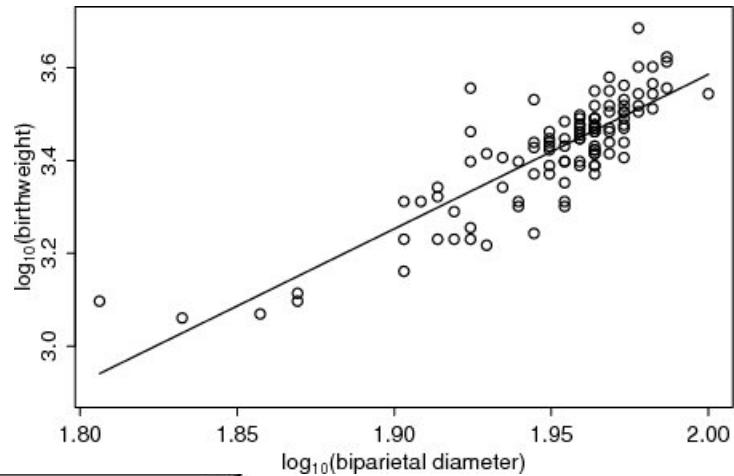
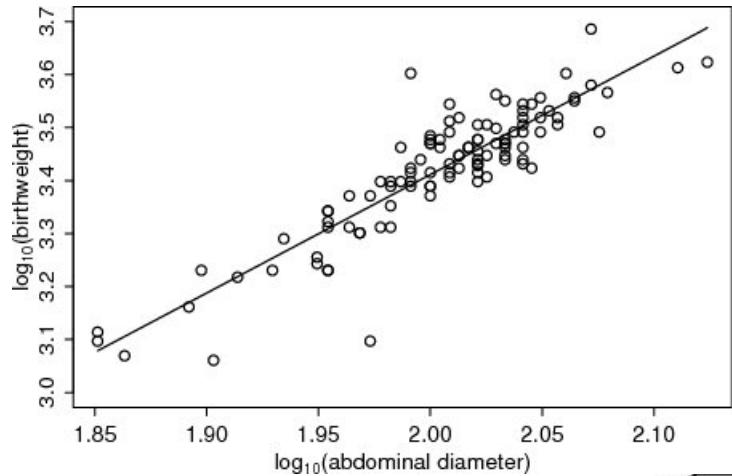
počet **prediktorů** je  $p$

počet **parametrů** je  $p+1=k$

počet **pozorování** je  $n$ .

# Víceprediktorová regrese

Model pro predikci porodní hmotnosti dle UZ markerů



# Rozepsané...

jednotlivá pozorování

$$\left[ \begin{array}{l} EY_1 = \beta_0 + \beta_1 x_{11} + \dots + \beta_p x_{1p} \\ EY_2 = \beta_0 + \beta_1 x_{21} + \dots + \beta_p x_{2p} \\ \vdots \\ EY_n = \beta_0 + \beta_1 x_{n1} + \dots + \beta_p x_{np} \end{array} \right]$$

# Maticový zápis

$$\begin{matrix} \text{závisle} \\ \text{proměnná} \end{matrix} \quad \quad \quad \begin{matrix} \text{systematická} \\ \text{složka} \end{matrix} \quad \quad \quad \begin{matrix} \text{náhodná} \\ \text{složka} \end{matrix}$$
$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & \cdots & x_{1p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \cdots & x_{np} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \vdots \\ \beta_p \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

matice plánu                      regresní koeficienty

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

# Normální lineární regresní model

- Náhodná složka modelu je reprezentována náhodnými chybami  $\varepsilon_i$ . Rozdělení těchto náhodných veličin  $\varepsilon_i$  je **normální**
- Rozptyl je všude stejný, pozorování jsou nezávislá

$$Y_i = \beta_0 + \sum_{j=1}^p \beta_j X_{ij} + \varepsilon_i, i = 1, \dots, n$$

$$\varepsilon_i \sim N(0, \sigma^2)$$

- předpokladem sestrojení statistik pro testy v tomto modelu

# Odhad neznámých parametrů

## Parametry $\beta$

- Odhad metodou nejmenších čtverců

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

- nejlepší, nestranný, lineární odhad  $\beta$  (BLUE)
- lze ukázat, že rozptyl tohoto odhadu je

$$D\hat{\beta}_{OLS} = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$$

# Odhad neznámých parametrů

## Reziduální součet čtverců

$$\begin{aligned} S_e &= (\mathbf{Y} - \hat{\mathbf{X}}\hat{\boldsymbol{\beta}}_{OLS})'(\mathbf{Y} - \hat{\mathbf{X}}\hat{\boldsymbol{\beta}}_{OLS}) \\ &= (\mathbf{Y} - \hat{\mathbf{Y}})'(\mathbf{Y} - \hat{\mathbf{Y}}) \\ &= (Y_1 - \hat{Y}_1)^2 + \dots + (Y_n - \hat{Y}_n)^2 \end{aligned}$$

↓  
Ize ukázat

$$S_e = \mathbf{Y}'\mathbf{Y} - \boldsymbol{\beta}'_{OLS}\mathbf{X}'\mathbf{Y}$$

# Odhad neznámých parametrů

## Rozptyl $\sigma^2$

$$s^2 = \frac{S_e}{n - k}$$

reziduální součet čtverců  
stupně volnosti modelu

# Statistické testy v lineárním regresním modelu

- **Testování lineární kombinace parametrů**
- Hypotéza:  
 $H_0: \mathbf{c}'\boldsymbol{\beta} = x$        $x \dots$  konstanta  
 $H_1: \mathbf{c}'\boldsymbol{\beta} \neq x$

- Testová statistika:

$$T = \frac{\mathbf{c}'\hat{\boldsymbol{\beta}}_{OLS} - \mathbf{c}'\boldsymbol{\beta}}{s\sqrt{\mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{c}}} \sim t(n-k)$$

- Speciálním případem je klasický t-test

# Statistické testy v lineárním regresním modelu

- **Testování více parametrů zároveň**
- Předpokládá blokové označení parametrů:

$$\begin{aligned}\boldsymbol{\beta} &= (\underbrace{\beta_1, \dots, \beta_m}_{= \boldsymbol{\beta}'_1}, \underbrace{\beta_{m+1}, \dots, \beta_k}_{= \boldsymbol{\beta}'_2})' \\ &= \boldsymbol{\beta}'_1 \quad \quad \quad = \boldsymbol{\beta}'_2\end{aligned}$$

- Obdobně i pro odhad

$$\boldsymbol{\beta} = \begin{pmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta}_2 \end{pmatrix} \quad \hat{\boldsymbol{\beta}}_{OLS} = \begin{pmatrix} \hat{\boldsymbol{\beta}}_{OLS,1} \\ \hat{\boldsymbol{\beta}}_{OLS,2} \end{pmatrix} \quad (\mathbf{X}'\mathbf{X})^{-1} = \begin{pmatrix} \mathbf{V}_{11} & \mathbf{V}_{12} \\ \mathbf{V}_{21} & \mathbf{V}_{22} \end{pmatrix}$$

# Statistické testy v lineárním regresním modelu

$$\boldsymbol{\beta} = \begin{pmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta}_2 \end{pmatrix} \quad \hat{\boldsymbol{\beta}}_{OLS} = \begin{pmatrix} \hat{\boldsymbol{\beta}}_{OLS,1} \\ \hat{\boldsymbol{\beta}}_{OLS,2} \end{pmatrix} \quad (\mathbf{X}'\mathbf{X})^{-1} = \begin{pmatrix} \mathbf{V}_{11} & \mathbf{V}_{12} \\ \mathbf{V}_{21} & \mathbf{V}_{22} \end{pmatrix}$$

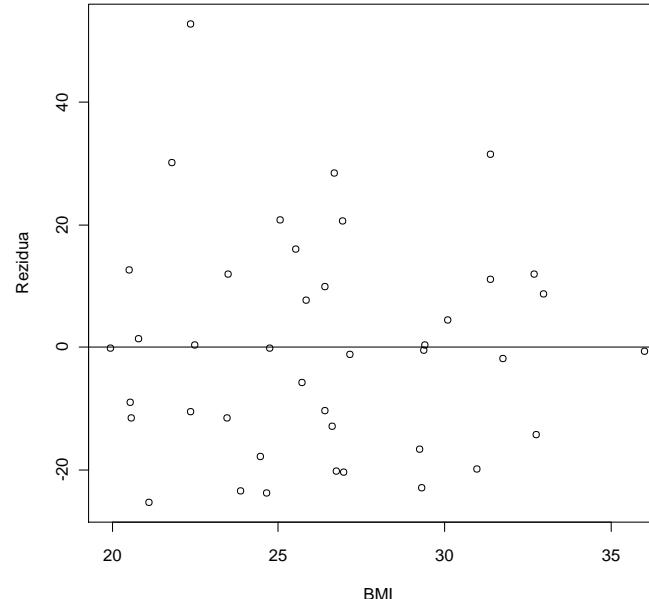
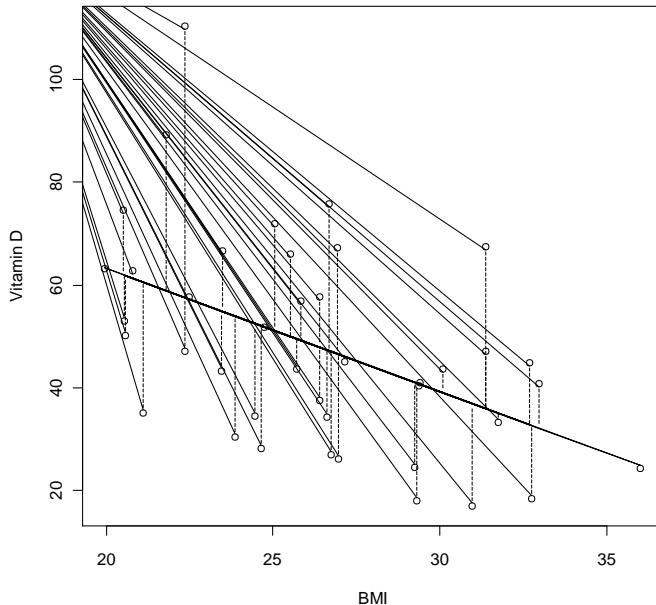
- Hypotéza  $H_0: \boldsymbol{\beta}_2 = \mathbf{x}$        $\mathbf{x}$  ... konstantní vektor  
 $H_1: \boldsymbol{\beta}_2 \neq \mathbf{x}$
- Statistikou je

$$F = \frac{1}{s^2(k-m)} (\hat{\boldsymbol{\beta}}_{OLS,2} - \boldsymbol{\beta}_2)' \mathbf{V}_{22}^{-1} (\hat{\boldsymbol{\beta}}_{OLS,2} - \boldsymbol{\beta}_2) \sim F(k-m, n-k)$$

- Speciálním případem je klasická analýza rozptylu

# Analýza reziduí

- V lineárním modelu jsou rezidua rozdíly mezi pozorovanými a odhadnutými (očekávanými) hodnotami závisle proměnné:  
$$\mathbf{r} = \hat{\boldsymbol{\epsilon}} = \mathbf{Y} - \hat{\mathbf{Y}}$$
- Hodnocení reziduí je nesmírně důležité pro posouzení splnění předpokladů modelu



# Koeficient determinace

Celková variabilita výsledku:

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

Reziduální součet čtverců:

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

Nevyčerpaná variabilita

**Koeficient determinace** = vyčerpaná variabilita výsledku modelem

$$R^2 = 1 - \frac{S_e}{S_T}$$

# Lineární regresní model I

**Prediktory různých datových typů**

# Matice plánu

- představuje matici nezávislých proměnných - prediktorů

$$\begin{array}{c} \text{závisle} \\ \text{proměnná} \\ \left( \begin{array}{c} Y_1 \\ \vdots \\ Y_n \end{array} \right) = \left( \begin{array}{ccc} 1 & x_{11} & \cdots & x_{1p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \cdots & x_{np} \end{array} \right) \left( \begin{array}{c} \beta_0 \\ \vdots \\ \beta_p \end{array} \right) + \left( \begin{array}{c} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{array} \right) \end{array}$$

**systematická složka**

**náhodná složka**

**matice plánu**

$$EY_1 = \beta_0 + \beta_1 x_{11} + \dots + \beta_p x_{1p}$$

$$EY_2 = \beta_0 + \beta_1 x_{21} + \dots + \beta_p x_{2p}$$

⋮

$$EY_n = \beta_0 + \beta_1 x_{n1} + \dots + \beta_p x_{np}$$

# Matice plánu

- představuje matici nezávislých proměnných – prediktorů
- promítají se do ní
  - konstanta – absolutní člen
  - spojité proměnné
  - kategoriální proměnné

# Konstanta – absolutní člen

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} \beta_0 + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

$$EY_1 = \beta_0$$

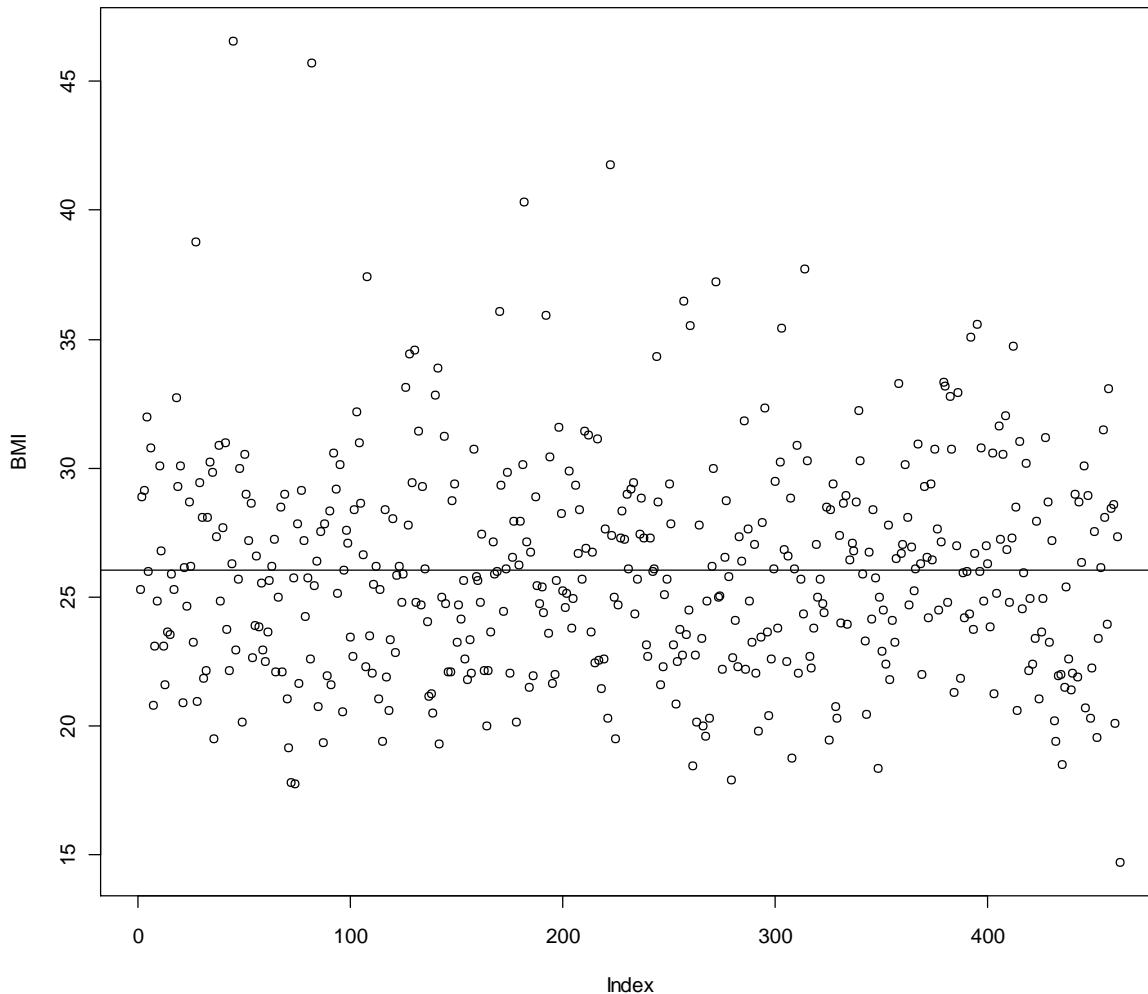
$$EY_2 = \beta_0$$

⋮

$$EY_n = \beta_0$$

- Předpokládáme stejnou střední hodnotu pro celý soubor – odhadli jsme výběrový průměr
- Sloupec jedniček budeme v matici plánu uvažovat téměř vždy

# Konstanta – absolutní člen

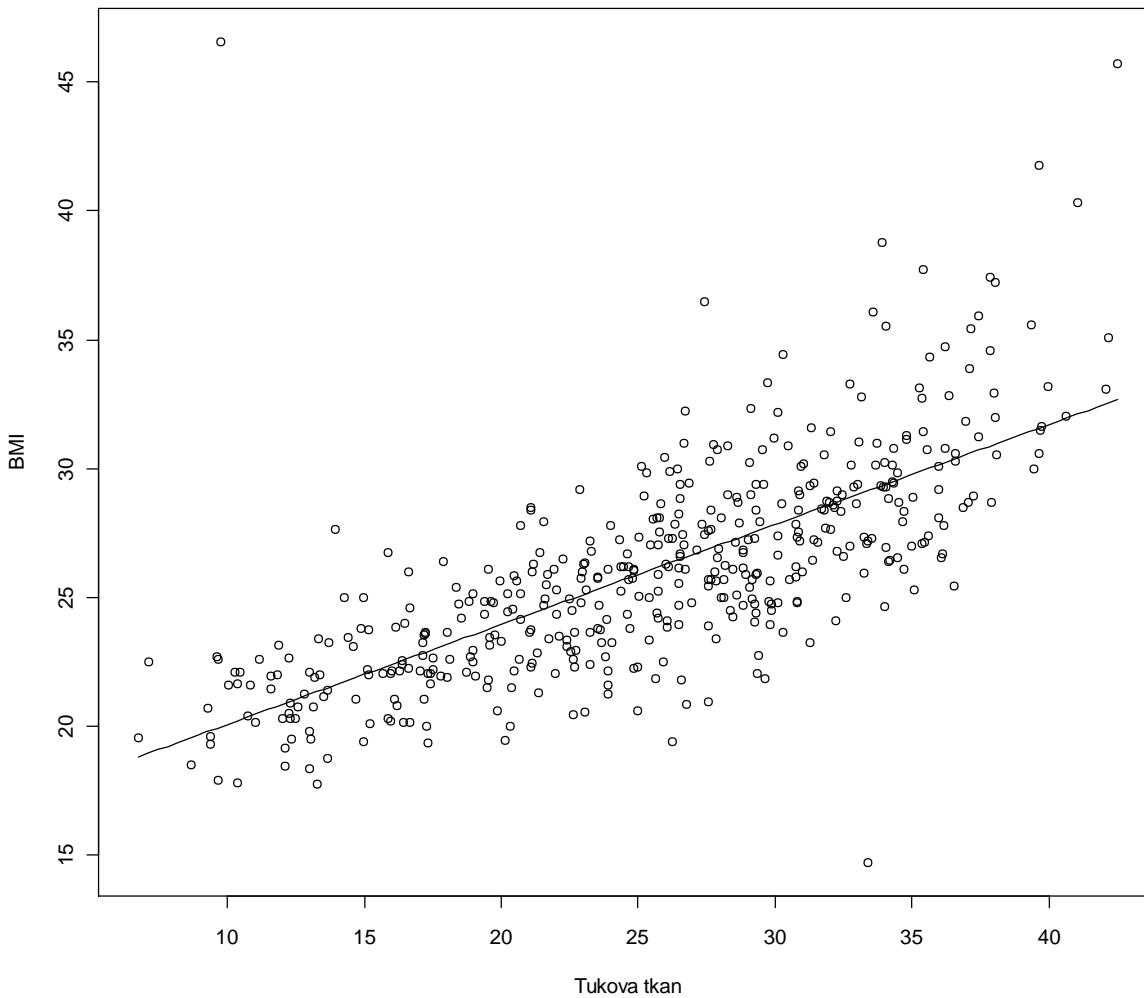


# Spojité prediktory

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$
$$EY_1 = \beta_0 + \beta_1 x_1$$
$$EY_2 = \beta_0 + \beta_1 x_2$$
$$\vdots$$
$$EY_n = \beta_0 + \beta_1 x_n$$

- Střední hodnota se lineárně mění v závislosti na prediktoru

# Spojité prediktory



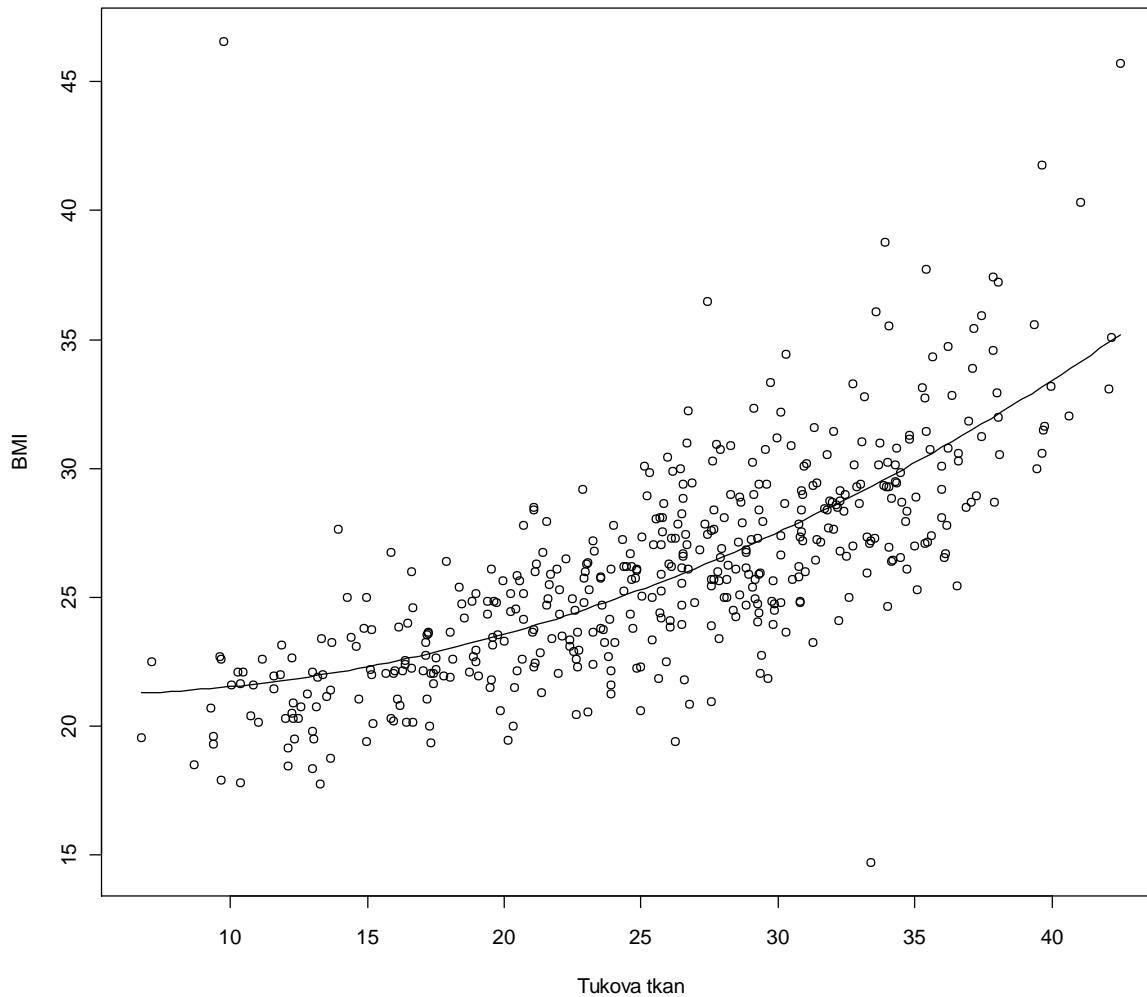
# Spojité prediktory – jak na polynom?

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_1 & x_1^2 \\ \vdots & & \vdots \\ 1 & x_n & x_n^2 \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

$$\begin{aligned} EY_1 &= \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 \\ EY_2 &= \beta_0 + \beta_1 x_2 + \beta_2 x_2^2 \\ &\vdots \\ EY_n &= \beta_0 + \beta_1 x_n + \beta_2 x_n^2 \end{aligned}$$

- Předpokládáme, že očekávaná hodnota opisuje parabolu
- Lze přidat flexibilitu přidáním další mocniny
- Pozor na multikolineritu a „znesmyslnění“ koeficientů
- NAJEDNOU UŽ LINEÁRNÍ MODELY NEJSOU TAK DOCELA LINEÁRNÍ
- Stále však musí platit, že lineární prediktor je lineární kombinací parametrů modelu

# Spojité prediktory – jak na polynom?



# Kategoriální prediktory

- Většinou nelze uvažovat jako kvantitativní
  - to by předpokládalo linearitu a stejné rozdíly mezi následujícími skupinami
- Je potřeba vytvořit tzv. dummy proměnné
- Vždy vytváříme o jednu proměnnou méně, než je hodnot kategoriálního prediktoru

# Kategoriální prediktory

## Nominální kódování

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & x_{13} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & x_{n3} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Původní	Nové proměnné		
BMI kateg.	Normální váha	Nadváha	Obezita
Podváha	0	0	0
Normální váha	1	0	0
Nadváha	0	1	0
Obezita	0	0	1

$$EY_i = \beta_0$$

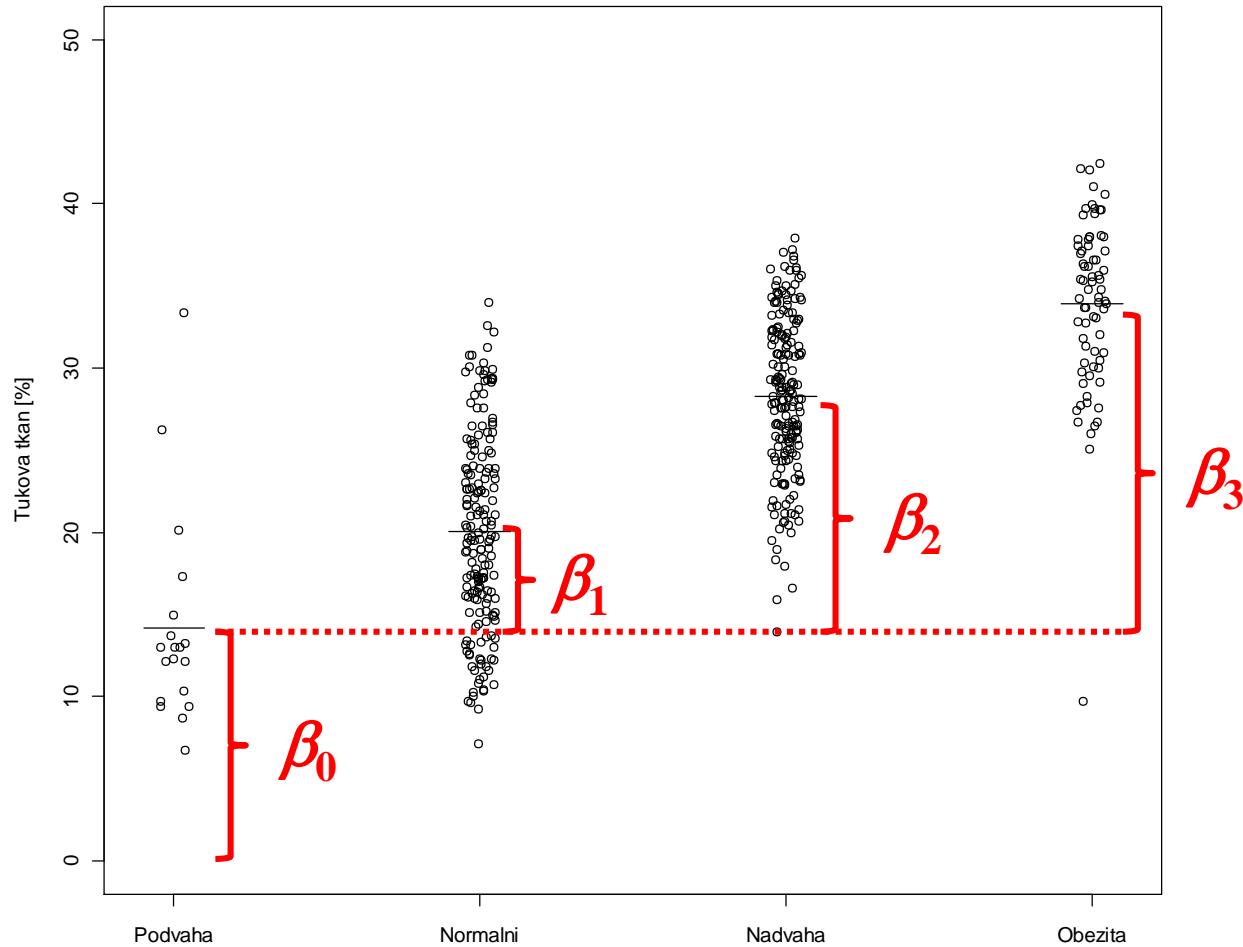
$$EY_i = \beta_0 + \beta_1$$

$$EY_i = \beta_0 + \beta_2$$

$$EY_i = \beta_0 + \beta_3$$

# Kategoriální prediktory

## Nominální kódování



# Kategoriální prediktory

## Ordinální kódování

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} 1 & x_{11} & x_{12} & x_{13} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & x_{n3} \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Původní	Nové proměnné		
BMI kateg.	Normální váha	Nadváha	Obezita
Podváha	0	0	0
Normální váha	1	0	0
Nadváha	1	1	0
Obezita	1	1	1

$$EY_i = \beta_0$$

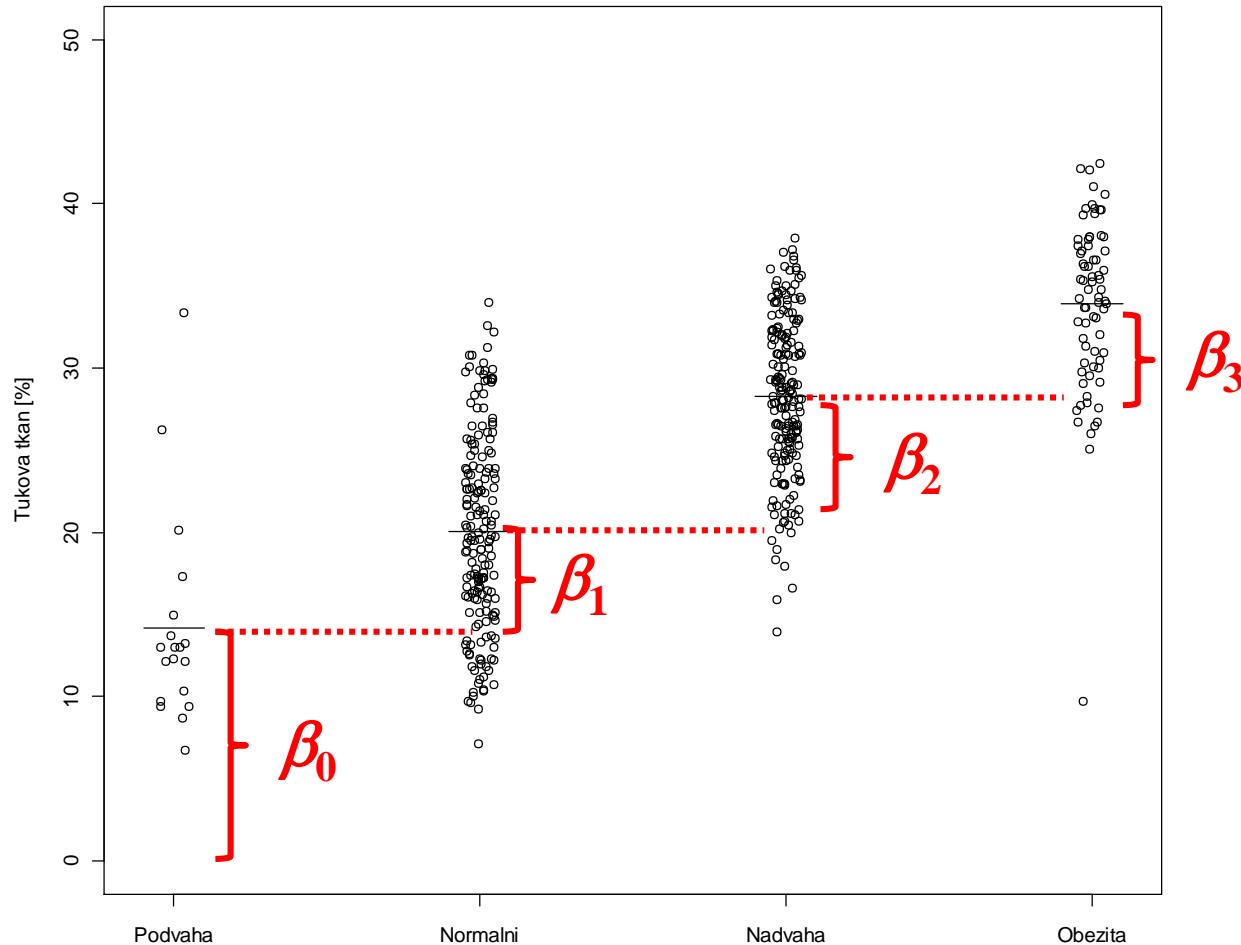
$$EY_i = \beta_0 + \beta_1$$

$$EY_i = \beta_0 + \beta_1 + \beta_2$$

$$EY_i = \beta_0 + \beta_1 + \beta_2 + \beta_3$$

# Kategoriální prediktory

## Ordinální kódování



# Lineární regresní model I

**Klasické modely novým pohledem**

# Co už známe, ale jinak...

## t-test

- jedná se o lineární model s jedním kategoriálním prediktorem se dvěma hodnotami

$$\mathbf{X} = \begin{pmatrix} 1 & 0 \\ \vdots & \vdots \\ 1 & 0 \\ \hline \cdots & \cdots \\ 1 & 1 \\ \vdots & \vdots \\ 1 & 1 \end{pmatrix} \quad EY_i = \mu \quad H_0: \alpha = 0$$
$$EY_i = \mu + \alpha \quad H_1: \alpha \neq 0$$

Použijeme výše zmíněný t-test pro lineární modely...

# Co už známe, ale jinak... analýza rozptylu

- jedná se o lineární model s jedním kategoriálním prediktorem s  $m$  hodnotami

$$\mathbf{X} = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & \cdots & 0 \\ \hline 1 & 1 & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 1 & \cdots & 0 \\ \hline \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & \cdots & 1 \\ \vdots & \vdots & \cdots & \vdots \\ 1 & 0 & \cdots & 1 \end{pmatrix}$$

$$EY_i = \mu$$

$$H_0: \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_{m-1} \end{pmatrix} = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}$$

$$EY_i = \mu + \alpha_1$$

$$H_1: \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_{m-1} \end{pmatrix} \neq \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}$$

$$EY_i = \mu + \alpha_{m-1}$$

Použijeme výše zmíněný F-test  
pro lineární modely...

# Lineární regresní model I

Předpoklady lineárního  
regresního modelu

# Předpoklady lineární regrese

LINEARITA

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, i = 1, \dots, n$$

ADITIVITA

$$\varepsilon_i \sim N(0, \sigma^2)$$

ROZLOŽENÍ REZIDUÍ

$$C(\varepsilon_i, \varepsilon_j) = 0, i \neq j$$

NEZÁVISLOST POZOROVÁNÍ

# Naučíme se s nimi vypořádat...

V prediktorech ... polynomiální zadání

**LINEARITA** V parametrech ... linkovací funkce

$$Y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, i = 1, \dots, n$$

**ADITIVITA**  
Interakce

$$\varepsilon_i \sim N(0, \sigma^2)$$

**ROZLOŽENÍ REZIDUÍ**  
Logistická/Poissonova regrese

$$C(\varepsilon_i, \varepsilon_j) = 0, i \neq j$$

**NEZÁVISLOST POZOROVÁNÍ**  
Korelační struktura – smíšený model

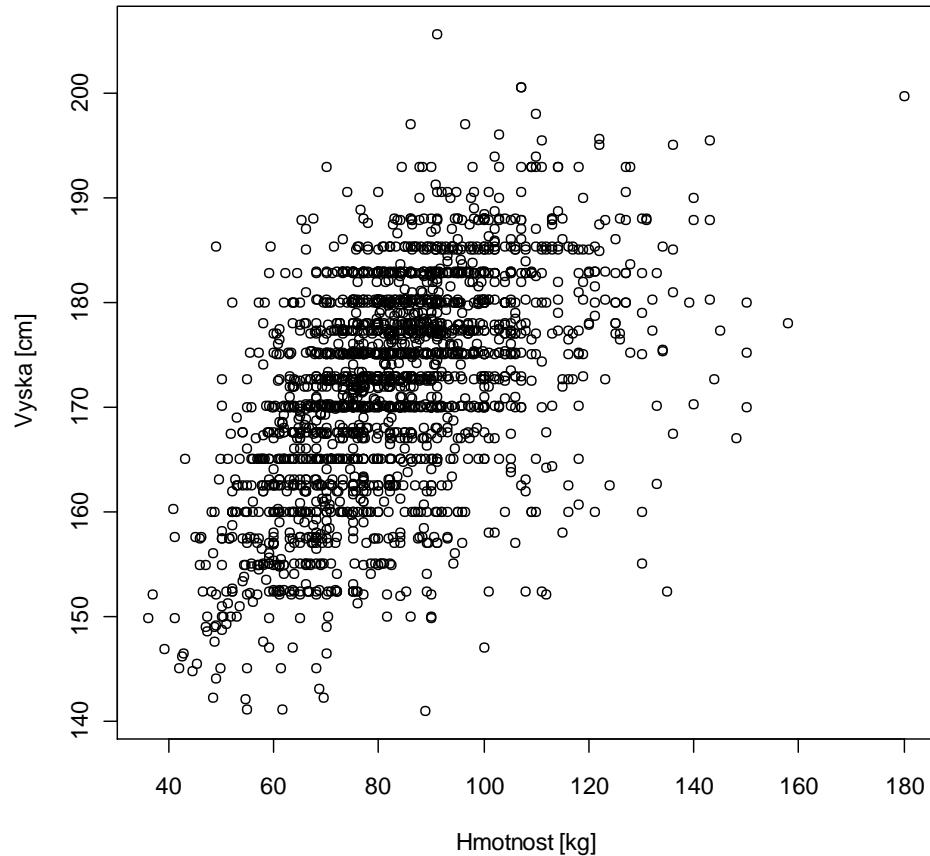
# Lineární regresní model I

## Multikolinearita

# Co je multikolinearita?

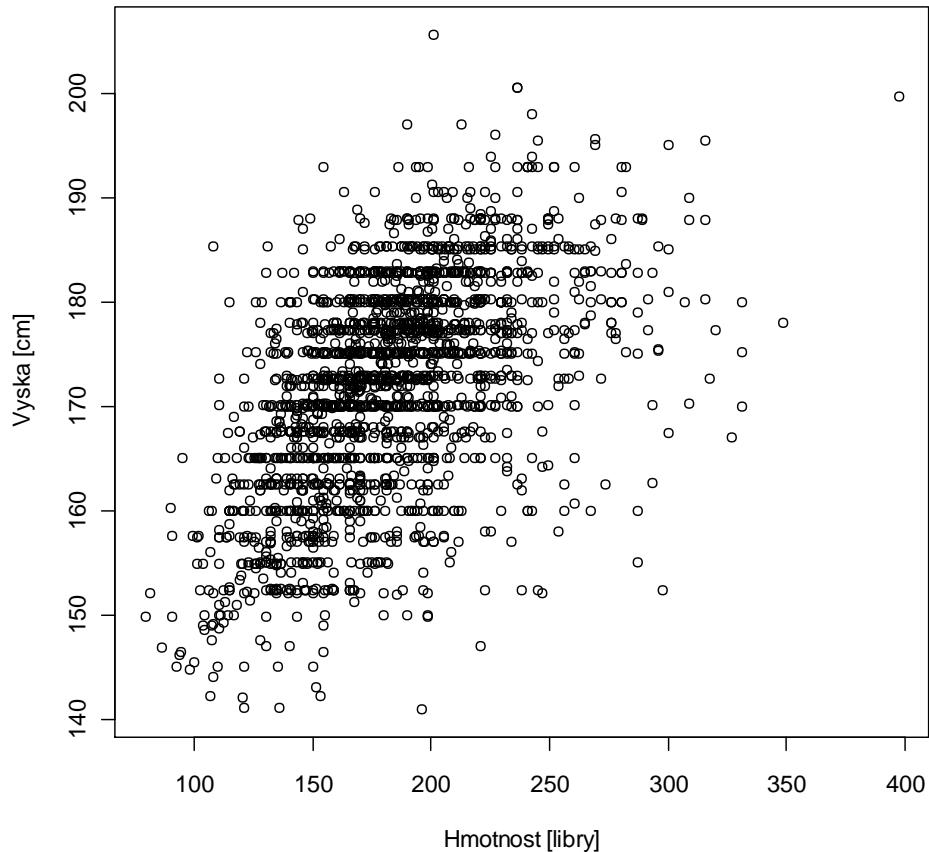
- Kdyby spolu proměnné nesouvisely, tak by víceprediktorová regrese pozbývala smyslu...
- Problém však představuje vysoká korelace mezi prediktory, neboť znemožňuje odhadnutí účinku jednotlivých prediktorů

# Příklad



$$\text{Výška} = 147 + \text{HmotnostKg} \times 0,3$$

# Příklad



$$\text{Výška} = 147 + \text{HmotnostLb} \times 0,14$$

# Příklad

- Co kdybychom dali do modelu obě proměnné?
- $Výška = \beta_0 + HmotnostKg \cdot \beta_1 + HmotnostLb \cdot \beta_2$
- $Výška = 147 + HmotnostKg \cdot 0,3 + HmotnostLb \cdot 0$
- $Výška = 147 + HmotnostKg \cdot 0 + HmotnostLb \cdot 0,14$
- $Výška = \beta_0 + (HmotnostLb \cdot 0,45) \cdot \beta_1 + HmotnostLb \cdot \beta_2$
- $Výška = \beta_0 + HmotnostLb \cdot (0,45 \cdot \beta_1 + \beta_2)$
- tedy kterékoliv koeficienty, které řeší  $0,45 \cdot \beta_1 + \beta_2 = 0,14$
- a těch je nekonečně mnoho...

# Problémy s multikolinearitou

- může se objevit divné chování
  - velké změny parametrů při odebrání/přidání prediktoru
  - obrovské směrodatné odchylky
  - extrémní odlehlé hodnoty
- software může upozornit na numerickou nestabilitu
- prediktory v automatických metodách jsou vybírány náhodně
- je obtížné skutečně odhadnout efekt
- může být i dobrý model na predikci, ale nepoužitelný na odhad efektu kovariát

# Jak najít dva korelované prediktory?

- Jak najít korelované proměnné?
  - Dvě proměnné – xy-graf, korelační matice
  - Korelační matice odhadnutých koeficientů

# Jak najít více korelovaných prediktorů?

- Ze dvou a více prediktorů lze spočítat jiný

## Tolerance

### Variance inflation factor (nafouknutí rozptylu)

- převrácená hodnota tolerance
- nad 4 znepokojivé, nad 10 závažné
- výpočet pro i-tý parametr

$$VIF_i = \frac{1}{1 - R_i^2}$$

- kde  $R_i^2$  je čtverec vícenásobné korelace mezi i-tým sloupcem matice plánu a ostatními sloupci (koeficient determinace modelu vysvětlující daný prediktor ostatními prediktory)

# Řešení

- Vypustit část korelovaných proměnných
  - ty, které obsahují chybějící data, hůře se měří, nebo jsou z jiných důvodů nedůvěryhodné
- Vytvoření a/nebo proměnné
- Zkombinovat prediktory do jednoho skóre
  - např. věk + výška + váha -> věk + BMI

# Lineární regresní model I

**Závěr**

# Co byste po dnešní hodině měli vědět a umět?

- ➔ Vědět, jak se definuje lineární regresní model
- ➔ Vysvětlit předpoklady regresních modelů
- ➔ Umět použít v lineárním regresním modelu různé typy prediktorů
- ➔ Vědět, co je multikolinearita, jak ji zjistit a jak se s ní vypořádat