

# Statistika

(MD360P03Z, MD360P03U)  
ak. rok 2007/2008

Karel Zvára

karel.zvara@mff.cuni.cz  
<http://www.karlin.mff.cuni.cz/~zvara>

(naposledy upraveno 3. prosince 2007)



# Regresy

- ▶ na rozdíl od korelace (síla závislosti) hledáme tvar (způsob) závislosti, zajímá nás také průkaznost závislosti
- ▶ snažíme se z daných hodnot **regresorů (nezávisle proměnných)** předpovědět hodnoty **závisle proměnné** (odezvy, vysvětlované proměnné)
- ▶ snažíme se variabilitu (kolísání hodnot) odezvy vysvětlit kolísáním regresorů
- ▶ prvně v tomto smyslu F. Galton (1886) při vyšetřování závislosti výšky potomků na průměrné výšce rodičů
- ▶ Pearson, Lee (1903): potomci otců o dva palce vyšších než průměr všech otců byli v průměru jen o palec vyšší než průměr synů; dvoupalcová odchylka se nereprodukovala celá, byl patrný návrat (**regres**) k průměru

# Regresy

- ▶ na rozdíl od korelace (síla závislosti) hledáme tvar (způsob) závislosti, zajímá nás také průkaznost závislosti
- ▶ snažíme se z daných hodnot **regresorů (nezávisle proměnných)** předpovědět hodnoty **závisle proměnné** (odezvy, vysvětlované proměnné)
- ▶ snažíme se variabilitu (kolísání hodnot) odezvy vysvětlit kolísáním regresorů
- ▶ prvně v tomto smyslu F. Galton (1886) při vyšetřování závislosti výšky potomků na průměrné výšce rodičů
- ▶ Pearson, Lee (1903): potomci otců o dva palce vyšších než průměr všech otců byli v průměru jen o palec vyšší než průměr synů; dvoupalcová odchylka se nereprodukovala celá, byl patrný návrat (**regres**) k průměru

# Regresy

- ▶ na rozdíl od korelace (síla závislosti) hledáme tvar (způsob) závislosti, zajímá nás také průkaznost závislosti
- ▶ snažíme se z daných hodnot **regresorů (nezávisle proměnných)** předpovědět hodnoty **závisle proměnné** (odezvy, vysvětlované proměnné)
- ▶ snažíme se variabilitu (kolísání hodnot) odezvy vysvětlit kolísáním regresorů
- ▶ prvně v tomto smyslu F. Galton (1886) při vyšetřování závislosti výšky potomků na průměrné výšce rodičů
- ▶ Pearson, Lee (1903): potomci otců o dva palce vyšších než průměr všech otců byli v průměru jen o palec vyšší než průměr synů; dvoupalcová odchylka se nereprodukovala celá, byl patrný návrat (**regres**) k průměru

# Regresy


- ▶ na rozdíl od korelace (síla závislosti) hledáme tvar (způsob) závislosti, zajímá nás také průkaznost závislosti
- ▶ snažíme se z daných hodnot **regresorů (nezávisle proměnných)** předpovědět hodnoty **závisle proměnné** (odezvy, vysvětlované proměnné)
- ▶ snažíme se variabilitu (kolísání hodnot) odezvy vysvětlit kolísáním regresorů
- ▶ prvně v tomto smyslu F. Galton (1886) při vyšetřování závislosti výšky potomků na průměrné výšce rodičů
- ▶ Pearson, Lee (1903): potomci otců o dva palce vyšších než průměr všech otců byli v průměru jen o palec vyšší než průměr synů; dvoupalcová odchylka se nereprodukovala celá, byl patrný návrat (**regres**) k průměru

# Regresy

- ▶ na rozdíl od korelace (síla závislosti) hledáme tvar (způsob) závislosti, zajímá nás také průkaznost závislosti
- ▶ snažíme se z daných hodnot **regresorů (nezávisle proměnných)** předpovědět hodnoty **závisle proměnné** (odezvy, vysvětlované proměnné)
- ▶ snažíme se variabilitu (kolísání hodnot) odezvy vysvětlit kolísáním regresorů
- ▶ prvně v tomto smyslu F. Galton (1886) při vyšetřování závislosti výšky potomků na průměrné výšce rodičů
- ▶ Pearson, Lee (1903): potomci otců o dva palce vyšších než průměr všech otců byli v průměru jen o palec vyšší než průměr synů; dvoupalcová odchylka se nereprodukovala celá, byl patrný návrat (**regres**) k průměru

# příklad: souvisí úmrtnost se zeměpisnou šířkou?

úmrtnost na melanom na 10 000 000 obyvatel v státech USA



# regresní přímka

- ▶ chování  $Y$  (úmrtnost, mortality) co nejlépe (nejvíce) vysvětlit lineární závislostí na  $x$  (zeměpisná šířka, latitude)
- ▶ (naše představa, předpoklad:) každé zem. šířce odpovídá jakási střední úmrtnost, ta závisí na zeměpisné šířce lineárně

$$\mathbb{E} Y_i = \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n$$

- ▶ parametry  $\beta_0, \beta_1$  odhadneme **metodou nejmenších čtverců** minimalizací přes  $\beta_0, \beta_1$  součtu čtverců „svislých“ odchylek

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

- ▶ výsledné minimum (pro  $\beta_0 = b_0, \beta_1 = b_1$ ) nazveme reziduální součet čtverců, tj.  $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2$

# regresní přímka

- ▶ chování  $Y$  (úmrtnost, mortality) co nejlépe (nejvíce) vysvětlit lineární závislostí na  $x$  (zeměpisná šířka, latitude)
- ▶ (naše představa, předpoklad:) každé zem. šířce odpovídá jakási střední úmrtnost, ta závisí na zeměpisné šířce lineárně

$$\mathbb{E} Y_i = \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n$$

- ▶ parametry  $\beta_0, \beta_1$  odhadneme **metodou nejmenších čtverců** minimalizací přes  $\beta_0, \beta_1$  součtu čtverců „svislých“ odchylek

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

- ▶ výsledné minimum (pro  $\beta_0 = b_0, \beta_1 = b_1$ ) nazveme reziduální součet čtverců, tj.  $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2$

## regresní přímka

- ▶ chování  $Y$  (úmrtnost, mortality) co nejlépe (nejvíce) vysvětlit lineární závislostí na  $x$  (zeměpisná šířka, latitude)
- ▶ (naše představa, předpoklad:) každé zem. šířce odpovídá jakási střední úmrtnost, ta závisí na zeměpisné šířce lineárně

$$\mathbb{E} Y_i = \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n$$

- ▶ parametry  $\beta_0, \beta_1$  odhadneme **metodou nejmenších čtverců** minimalizací přes  $\beta_0, \beta_1$  součtu čtverců „svislých“ odchylek

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

- ▶ výsledné minimum (pro  $\beta_0 = b_0, \beta_1 = b_1$ ) nazveme reziduální součet čtverců, tj.  $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2$

# regresní přímka

- ▶ chování  $Y$  (úmrtnost, mortality) co nejlépe (nejvíce) vysvětlit lineární závislostí na  $x$  (zeměpisná šířka, latitude)
- ▶ (naše představa, předpoklad:) každé zem. šířce odpovídá jakási střední úmrtnost, ta závisí na zeměpisné šířce lineárně

$$\mathbb{E} Y_i = \beta_0 + \beta_1 x_i, \quad i = 1, \dots, n$$

- ▶ parametry  $\beta_0, \beta_1$  odhadneme **metodou nejmenších čtverců** minimalizací přes  $\beta_0, \beta_1$  součtu čtverců „svislých“ odchylek

$$\min_{\beta_0, \beta_1} \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2$$

- ▶ výsledné minimum (pro  $\beta_0 = b_0, \beta_1 = b_1$ ) nazveme **reziduální součet čtverců**, tj.  $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2$

# metoda nejmenších čtverců


odhadovaná závislost:

$$y = \beta_0 + \beta_1 \cdot x \quad (\text{populace})$$

odhad závislosti:

$$y = b_0 + b_1 \cdot x \quad (\text{výběr})$$

celková plocha čtverců:  $S_e = \sum_{i=1}^n (Y_i - b_0 - b_1 x_i)^2 \quad (\text{výběr})$



# náš příklad

[summary(lm(mortality~latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	389,19	23,81	16,34	<0,001
latitude	- 5,98	0,60	- 9,99	<0,001

- ▶ odhad závislosti:  $\widehat{\text{mortality}} = 389,19 - 5,98 \text{ latitude}$
- ▶ s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 6 osob na 10 000 000 obyvatel
- ▶ na rovníku by úmrtnost měla být 389 jednotek, ale je to extrapolace mimo rozmezí známých hodnot – sotva použitelné
- ▶ závislost je průkazná, neboť v řádku pro  $x$  (latitude) je  $p < 0,001$

# náš příklad

[summary(lm(mortality~latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	389,19	23,81	16,34	<0,001
latitude	- 5,98	0,60	- 9,99	<0,001

- ▶ odhad závislosti:  $\widehat{\text{mortality}} = 389,19 - 5,98 \text{ latitude}$
- ▶ s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 6 osob na 10 000 000 obyvatel
- ▶ na rovníku by úmrtnost měla být 389 jednotek, ale je to extrapolace mimo rozmezí známých hodnot – sotva použitelné
- ▶ závislost je průkazná, neboť v řádku pro  $x$  (latitude) je  $p < 0,001$

# náš příklad

[summary(lm(mortality~latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	389,19	23,81	16,34	<0,001
latitude	- 5,98	0,60	- 9,99	<0,001

- ▶ odhad závislosti:  $\widehat{\text{mortality}} = 389,19 - 5,98 \text{ latitude}$
- ▶ s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 6 osob na 10 000 000 obyvatel
- ▶ na rovníku by úmrtnost měla být 389 jednotek, ale je to extrapolace mimo rozmezí známých hodnot – sotva použitelné
- ▶ závislost je průkazná, neboť v řádku pro  $x$  (latitude) je  $p < 0,001$

# náš příklad

[summary(lm(mortality~latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	389,19	23,81	16,34	<0,001
latitude	- 5,98	0,60	- 9,99	<0,001

- ▶ odhad závislosti:  $\widehat{\text{mortality}} = 389,19 - 5,98 \text{ latitude}$
- ▶ s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 6 osob na 10 000 000 obyvatel
- ▶ na rovníku by úmrtnost měla být 389 jednotek, ale je to extrapolace mimo rozmezí známých hodnot – sotva použitelné
- ▶ závislost je průkazná, neboť v řádku pro  $x$  (latitude) je  $p < 0,001$

## obecně

- ▶ odhadovaná závislost  $y = \beta_0 + \beta_1 x$ , odhadnutá  $y = b_0 + b_1 x$
- ▶ závislost na  $x$  prokazujeme testováním hypotézy  $H_0 : \beta_1 = 0$   
(pak je  $y$  pro všechna  $x$  stejné, tedy  $y = \beta_0$ ) pomocí

$$T = \frac{b_1}{\text{S.E.}(b_1)} = \frac{b_1}{s} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- ▶ zamítáme  $H_0$  proti oboustr. alternativě, když  $|T| \geq t_{n-2}(\alpha)$
- ▶ reziduální součet čtverců – nevysvětlená variabilita  $Y$   
 $S_e = \sum_{i=1}^n (Y_i - (b_0 + b_1 x_i))^2$  reziduální součet čtverců  
 $s^2 = S_e / (n - 2)$  reziduální rozptyl
- ▶ koeficient determinace ukazuje, jaký díl variability odezvy (tj.  $\sum_{i=1}^n (Y_i - \bar{Y})^2$ ) jsme závislostí vysvětlili

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

## obecně

- ▶ odhadovaná závislost  $y = \beta_0 + \beta_1 x$ , odhadnutá  $y = b_0 + b_1 x$
- ▶ závislost na  $x$  prokazujeme testováním hypotézy  $H_0 : \beta_1 = 0$   
(pak je  $y$  pro všechna  $x$  stejné, tedy  $y = \beta_0$ ) pomocí

$$T = \frac{b_1}{\text{S.E.}(b_1)} = \frac{b_1}{s} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- ▶ zamítáme  $H_0$  proti oboustr. alternativě, když  $|T| \geq t_{n-2}(\alpha)$
- ▶ reziduální součet čtverců – nevysvětlená variabilita  $Y$   
 $S_e = \sum_{i=1}^n (Y_i - (b_0 + b_1 x_i))^2$  reziduální součet čtverců  
 $s^2 = S_e / (n - 2)$  reziduální rozptyl
- ▶ koeficient determinace ukazuje, jaký díl variability odezvy (tj.  $\sum_{i=1}^n (Y_i - \bar{Y})^2$ ) jsme závislostí vysvětlili

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

## obecně

- ▶ odhadovaná závislost  $y = \beta_0 + \beta_1 x$ , odhadnutá  $y = b_0 + b_1 x$
- ▶ závislost na  $x$  prokazujeme testováním hypotézy  $H_0 : \beta_1 = 0$   
(pak je  $y$  pro všechna  $x$  stejné, tedy  $y = \beta_0$ ) pomocí

$$T = \frac{b_1}{\text{S.E.}(b_1)} = \frac{b_1}{s} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- ▶ zamítáme  $H_0$  proti oboustr. alternativě, když  $|T| \geq t_{n-2}(\alpha)$
- ▶ reziduální součet čtverců – nevysvětlená variabilita  $Y$   
 $S_e = \sum_{i=1}^n (Y_i - (b_0 + b_1 x_i))^2$  reziduální součet čtverců  
 $s^2 = S_e / (n - 2)$  reziduální rozptyl
- ▶ koeficient determinace ukazuje, jaký díl variability odezvy (tj.  $\sum_{i=1}^n (Y_i - \bar{Y})^2$ ) jsme závislostí vysvětlili

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

## obecně

- ▶ odhadovaná závislost  $y = \beta_0 + \beta_1 x$ , odhadnutá  $y = b_0 + b_1 x$
- ▶ závislost na  $x$  prokazujeme testováním hypotézy  $H_0 : \beta_1 = 0$   
(pak je  $y$  pro všechna  $x$  stejné, tedy  $y = \beta_0$ ) pomocí

$$T = \frac{b_1}{\text{S.E.}(b_1)} = \frac{b_1}{s} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- ▶ zamítáme  $H_0$  proti oboustr. alternativě, když  $|T| \geq t_{n-2}(\alpha)$
- ▶ **reziduální součet čtverců – nevysvětlená variabilita  $Y$**   
 $S_e = \sum_{i=1}^n (Y_i - (b_0 + b_1 x_i))^2$  reziduální součet čtverců  
 $s^2 = S_e / (n - 2)$  reziduální rozptyl
- ▶ **koeficient determinace** ukazuje, jaký díl variability odezvy (tj.  $\sum_{i=1}^n (Y_i - \bar{Y})^2$ ) jsme závislostí vysvětlili

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

## obecně

- ▶ odhadovaná závislost  $y = \beta_0 + \beta_1 x$ , odhadnutá  $y = b_0 + b_1 x$
- ▶ závislost na  $x$  prokazujeme testováním hypotézy  $H_0 : \beta_1 = 0$   
(pak je  $y$  pro všechna  $x$  stejné, tedy  $y = \beta_0$ ) pomocí

$$T = \frac{b_1}{\text{S.E.}(b_1)} = \frac{b_1}{s} \sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- ▶ zamítáme  $H_0$  proti oboustr. alternativě, když  $|T| \geq t_{n-2}(\alpha)$
- ▶ **reziduální součet čtverců – nevysvětlená variabilita  $Y$**   
 $S_e = \sum_{i=1}^n (Y_i - (b_0 + b_1 x_i))^2$  reziduální součet čtverců  
 $s^2 = S_e / (n - 2)$  reziduální rozptyl
- ▶ **koeficient determinace** ukazuje, jaký **díl variability odezvy** (tj.  $\sum_{i=1}^n (Y_i - \bar{Y})^2$ ) jsme závislostí vysvětlili

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

# náš příklad a tabulka analýzy rozptylu

[anova(lm(mortality~latitude))]

variabilita	st. vol. <i>f</i>	součet čtverců <i>SS</i>	prům. čtverec <i>MS</i>	<i>F</i>	<i>p</i>
model	1	36 464,20	36 464,20	99,797	<0,001
reziduální	47	17 173,07	365,38		
celkem	48	53 637,27			

- kolísání úmrtnosti vysvětlíme závislostí z 68 %, neboť je

$$R^2 = 1 - \frac{17173,07}{53637,27} = \frac{36464,20}{53637,27} = 0,680$$

# interpretace

- ▶ odhad byl:  $\widehat{\text{úmrtnost}} = 389,19 - 5,98 \cdot \text{šířka}$
- ▶ na 30. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 30 = 209,86$
- ▶ na 40. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 40 = 150,08$
- ▶ přechod z 30. stupně na 40. stupeň znamená **v průměru**  
pokles o  $10 \cdot 5,98 = 59,8$  úmrtí na 10 000 000 obyvatel
- ▶ pokusíme se predikci zlepšit přidáním další nezávisle promenné

# interpretace

- ▶ odhad byl:  $\widehat{\text{úmrtnost}} = 389,19 - 5,98 \cdot \text{šířka}$
- ▶ na 30. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 30 = 209,86$
- ▶ na 40. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 40 = 150,08$
- ▶ přechod z 30. stupně na 40. stupeň znamená v průměru pokles o  $10 \cdot 5,98 = 59,8$  úmrtí na 10 000 000 obyvatel
- ▶ pokusíme se predikci zlepšit přidáním další nezávisle promenné

# interpretace

- ▶ odhad byl:  $\widehat{\text{úmrtnost}} = 389,19 - 5,98 \cdot \text{šířka}$
- ▶ na 30. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 30 = 209,86$
- ▶ na 40. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 40 = 150,08$
- ▶ přechod z 30. stupně na 40. stupeň znamená v průměru pokles o  $10 \cdot 5,98 = 59,8$  úmrtí na 10 000 000 obyvatel
- ▶ pokusíme se predikci zlepšit přidáním další nezávisle promenné

## interpretace

- ▶ odhad byl:  $\widehat{\text{úmrtnost}} = 389,19 - 5,98 \cdot \text{šířka}$
- ▶ na 30. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 30 = 209,86$
- ▶ na 40. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 40 = 150,08$
- ▶ přechod z 30. stupně na 40. stupeň znamená **v průměru**  
pokles o  $10 \cdot 5,98 = 59,8$  úmrtí na 10 000 000 obyvatel
- ▶ pokusíme se predikci zlepšit přidáním další nezávisle promenné

## interpretace

- ▶ odhad byl:  $\widehat{\text{úmrtnost}} = 389,19 - 5,98 \cdot \text{šířka}$
- ▶ na 30. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 30 = 209,86$
- ▶ na 40. stupni očekáváme úmrtnost:  
 $389,19 - 5,98 \cdot 40 = 150,08$
- ▶ přechod z 30. stupně na 40. stupeň znamená **v průměru** pokles o  $10 \cdot 5,98 = 59,8$  úmrtí na 10 000 000 obyvatel
- ▶ pokusíme se predikci zlepšit přidáním další nezávisle proměnné

## dva regresory

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	401,17	28,04	14,31	<0,001
latitude	- 5,93	0,60	- 9,82	<0,001
longitude	0,15	0,19	0,82	0,418

- ▶ pokusíme se přidat zeměpisnou délku
- ▶ není průkazné, že by koeficient u longitude byl nenulový  
(nezamítne hypotézu, že koeficient je nulový)
- ▶ longitude nepřináší další informaci o mortality, kterou bychom už neměli ze známé hodnoty latitude
- ▶ ⇒ není vhodné přidávat do modelu s latitude také longitude
- ▶ koeficient determinace  $R^2 = 0,684$  (původně 0,680)

## dva regresory

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	401,17	28,04	14,31	<0,001
latitude	- 5,93	0,60	- 9,82	<0,001
longitude	0,15	0,19	0,82	0,418

- ▶ pokusíme se přidat zeměpisnou délku
- ▶ není průkazné, že by koeficient u longitude byl nenulový  
(nezamítne hypotézu, že koeficient je nulový)
- ▶ longitude nepřináší další informaci o mortality, kterou bychom už neměli ze známé hodnoty latitude
- ▶ ⇒ není vhodné přidávat do modelu s latitude také longitude
- ▶ koeficient determinace  $R^2 = 0,684$  (původně 0,680)

## dva regresory

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	401,17	28,04	14,31	<0,001
latitude	- 5,93	0,60	- 9,82	<0,001
longitude	0,15	0,19	0,82	0,418

- ▶ pokusíme se přidat zeměpisnou délku
- ▶ není průkazné, že by koeficient u longitude byl nenulový  
(nezamítne hypotézu, že koeficient je nulový)
- ▶ longitude nepřináší další informaci o mortality, kterou bychom už neměli ze známé hodnoty latitude
- ▶ ⇒ není vhodné přidávat do modelu s latitude také longitude
- ▶ koeficient determinace  $R^2 = 0,684$  (původně 0,680)

## dva regresory

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	401,17	28,04	14,31	<0,001
latitude	- 5,93	0,60	- 9,82	<0,001
longitude	0,15	0,19	0,82	0,418

- ▶ pokusíme se přidat zeměpisnou délku
- ▶ není průkazné, že by koeficient u longitude byl nenulový  
(nezamítne hypotézu, že koeficient je nulový)
- ▶ longitude nepřináší další informaci o mortality, kterou bychom už neměli ze známé hodnoty latitude
- ▶ ⇒ není vhodné přidávat do modelu s latitude také longitude
- ▶ koeficient determinace  $R^2 = 0,684$  (původně 0,680)

## dva regresory

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	401,17	28,04	14,31	<0,001
latitude	- 5,93	0,60	- 9,82	<0,001
longitude	0,15	0,19	0,82	0,418

- ▶ pokusíme se přidat zeměpisnou délku
- ▶ není průkazné, že by koeficient u longitude byl nenulový  
(nezamítne hypotézu, že koeficient je nulový)
- ▶ longitude nepřináší další informaci o mortality, kterou bychom už neměli ze známé hodnoty latitude
- ▶ ⇒ není vhodné přidávat do modelu s latitude také longitude
- ▶ koeficient determinace  $R^2 = 0,684$  (původně 0,680)

## podrobnější rozbor – vliv oceánu

- závislost jen pro vnitrozemské státy ( $R^2 = 59,6\%$ ):  
 $\text{[lm(mortality} \sim \text{latitude, subset=Ocean==0)]}$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,55	36,70	9,82	<0,001
latitude	- 5,485	0,904	- 6,07	<0,001

- závislost jen pro přímořské státy ( $R^2 = 78,6\%$ ):  
 $\text{[lm(mortality} \sim \text{latitude, subset=Ocean==1)]}$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	381,20	24,83	15,35	<0,001
latitude	- 5,491	0,640	- 8,58	<0,001

- směrnice jsou téměř stejné, abs. členy rozdílné
- v obou případech s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 5,5 osob na 10 000 000 obyvatel

## podrobnější rozbor – vliv oceánu

- ▶ závislost jen pro vnitrozemské státy ( $R^2 = 59,6\%$ ):  
 $[lm(mortality \sim latitude, subset=Ocean==0)]$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,55	36,70	9,82	<0,001
latitude	- 5,485	0,904	- 6,07	<0,001

- ▶ závislost jen pro přímořské státy ( $R^2 = 78,6\%$ ):  
 $[lm(mortality \sim latitude, subset=Ocean==1)]$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	381,20	24,83	15,35	<0,001
latitude	- 5,491	0,640	- 8,58	<0,001

- ▶ směrnice jsou téměř stejné, abs. členy rozdílné
- ▶ v obou případech s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 5,5 osob na 10 000 000 obyvatel

## podrobnější rozbor – vliv oceánu

- ▶ závislost jen pro vnitrozemské státy ( $R^2 = 59,6\%$ ):  
 $[lm(mortality \sim latitude, subset = Ocean == 0)]$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,55	36,70	9,82	<0,001
latitude	- 5,485	0,904	- 6,07	<0,001

- ▶ závislost jen pro přímořské státy ( $R^2 = 78,6\%$ ):  
 $[lm(mortality \sim latitude, subset = Ocean == 1)]$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	381,20	24,83	15,35	<0,001
latitude	- 5,491	0,640	- 8,58	<0,001

- ▶ směrnice jsou téměř stejné, abs. členy rozdílné
- ▶ v obou případech s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 5,5 osob na 10 000 000 obyvatel

## podrobnější rozbor – vliv oceánu

- ▶ závislost jen pro vnitrozemské státy ( $R^2 = 59,6\%$ ):  
 $[lm(mortality \sim latitude, subset = Ocean == 0)]$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,55	36,70	9,82	<0,001
latitude	- 5,485	0,904	- 6,07	<0,001

- ▶ závislost jen pro přímořské státy ( $R^2 = 78,6\%$ ):  
 $[lm(mortality \sim latitude, subset = Ocean == 1)]$

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	381,20	24,83	15,35	<0,001
latitude	- 5,491	0,640	- 8,58	<0,001

- ▶ směrnice jsou téměř stejné, abs. členy rozdílné
- ▶ v obou případech s každým stupněm sev. šířky klesá úmrtnost v průměru téměř o 5,5 osob na 10 000 000 obyvatel

# společně vnitrozemské i přímořské státy

[summary(lm(mortality~Ocean+latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,69	21,50	16,78	<0,001
ocean	20,43	4,83	4,23	<0,001
latitude	- 5,49	0,53	- 10,44	<0,001

- ▶ koeficient determinace  $R^2=0,770$
- ▶ při „stěhování“ z vnitrozemí k oceánu po rovnoběžce roste úmrtnost v průměru o 20 osob na 10 milionů obyvatel
- ▶ je to ekvivalentní vnitrozemskému stěhování o  $20,43/5,49 = 3,72$  stupňů na jih
- ▶ na každý stupeň stěhování na sever klesá úmrtnost o 5,5, pokud se nezmění vztah k oceánu

# společně vnitrozemské i přímořské státy

[summary(lm(mortality~Ocean+latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,69	21,50	16,78	<0,001
ocean	20,43	4,83	4,23	<0,001
latitude	- 5,49	0,53	- 10,44	<0,001

- ▶ koeficient determinace  $R^2=0,770$
- ▶ při „stěhování“ z vnitrozemí k oceánu po rovnoběžce roste úmrtnost v průměru o 20 osob na 10 milionů obyvatel
- ▶ je to ekvivalentní vnitrozemskému stěhování o  $20,43/5,49 = 3,72$  stupňů na jih
- ▶ na každý stupeň stěhování na sever klesá úmrtnost o 5,5, pokud se nezmění vztah k oceánu

# společně vnitrozemské i přímořské státy

[summary(lm(mortality~Ocean+latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,69	21,50	16,78	<0,001
ocean	20,43	4,83	4,23	<0,001
latitude	- 5,49	0,53	- 10,44	<0,001

- ▶ koeficient determinace  $R^2=0,770$
- ▶ při „stěhování“ z vnitrozemí k oceánu po rovnoběžce roste úmrtnost v průměru o 20 osob na 10 milionů obyvatel
- ▶ je to ekvivalentní vnitrozemskému stěhování o  $20,43/5,49 = 3,72$  stupňů na jih
- ▶ na každý stupeň stěhování na sever klesá úmrtnost o 5,5, pokud se nezmění vztah k oceánu


# společně vnitrozemské i přímořské státy

[summary(lm(mortality~Ocean+latitude))]

koef.	odhad	stř. chyba	t-stat.	p
abs. člen	360,69	21,50	16,78	<0,001
ocean	20,43	4,83	4,23	<0,001
latitude	- 5,49	0,53	- 10,44	<0,001

- ▶ koeficient determinace  $R^2=0,770$
- ▶ při „stěhování“ z vnitrozemí k oceánu po rovnoběžce roste úmrtnost v průměru o 20 osob na 10 milionů obyvatel
- ▶ je to ekvivalentní vnitrozemskému stěhování o  $20,43/5,49 = 3,72$  stupňů na jih
- ▶ na každý stupeň stěhování na sever klesá úmrtnost o 5,5, pokud se nezmění vztah k oceánu

## příklad: souvisí úmrtnost s polohou?



- ▶ vnitrozemské státy:  $y = 360,69 - 5,49 \times$   
přímořské státy:  $y = (360,69 + 20,43) - 5,49 \times = 381,12 - 5,49 \times$
- ▶ lze ověřit, že přímky mohou být rovnoběžné ( $p = 99,6\%$ )

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce?  
pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
- ▶  $\widehat{\text{fat}} = -47,68 + 0,341 \text{ height}$   $R^2 = 11,8\%$
- ▶  $\widehat{\text{fat}} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4\%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky  
(a nezměněné hmotnosti pro druhý model)

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce?  
pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
  - ▶  $\widehat{\text{fat}} = -47,68 + 0,341 \text{ height}$   $R^2 = 11,8\%$
  - ▶  $\widehat{\text{fat}} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4\%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky  
(a nezměněné hmotnosti pro druhý model)

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce?  
pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
- ▶  $\widehat{\text{fat}} = -47,68 + 0,341 \text{ height}$   $R^2 = 11,8\%$
- ▶  $\widehat{\text{fat}} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4\%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky  
(a nezměněné hmotnosti pro druhý model)

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce?  
pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
- ▶  $\widehat{\text{fat}} = -47,68 + 0,341 \text{ height}$   $R^2 = 11,8\%$
- ▶  $\widehat{\text{fat}} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4\%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky  
(a nezměněné hmotnosti pro druhý model)

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce?  
pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
- ▶  $\widehat{\text{fat}} = -47,68 + 0,341 \text{ height}$   $R^2 = 11,8\%$
- ▶  $\widehat{\text{fat}} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4\%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky  
(a nezměněné hmotnosti pro druhý model)

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce?  
pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
- ▶  $\widehat{\text{fat}} = -47,68 + 0,341 \text{ height}$   $R^2 = 11,8\%$
- ▶  $\widehat{\text{fat}} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4\%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky  
(a nezměněné hmotnosti pro druhý model)

## pozor na interpretaci odhadů (na dalším příkladu)

- ▶ závisí procento tuku dospělého muže na jeho výšce?  
pokud ano, tak s výškou roste nebo klesá?
- ▶ závisí na tom, jak se na úlohu díváme, co bereme v úvahu
- ▶  $\widehat{\text{fat}} = -47,68 + 0,341 \text{ height}$   $R^2 = 11,8\%$
- ▶  $\widehat{\text{fat}} = 16,55 - 0,244 \text{ height} + 0,504 \text{ weight}$   $R^2 = 71,4\%$
- ▶ ve všech případech jsou koeficienty u regresorů na 5% hladině průkazně nenulové
- ▶ rozdíl je v kvalitě vyrovnání, ale zejména v interpretaci
- ▶ průměrná změna procenta tuku při jednotkové změně výšky  
**(a nezměněné hmotnosti pro druhý model)**

# regrese v MS Excelu 2000, 2003

	Excel 2000	označení
absolutní člen odhadu	Hranice	$b_0$
střední chyba odhadu koeficient	Koeficienty	$b_i$
(mnohonásobné) korelace	Chyba střední hodnoty	$S.E.(b_j)$
koeficient determinace	Násobné R	$\sqrt{R^2}$
adjustovaný koef. det.	Hodnota spolehlivosti R	$R^2$
resid. směr. odchylka	Nastavená hodnota spol. R	$R^2_{adj}$
počet pozorování	Chyba střední hodnoty	$s$
počet st. volnosti	Pozorování	$n$
	Rozdíl	

# regrese v MS Excelu 2000, 2003



- ▶ Pozor na nabízený graf „Graf s rozdělením pravděpodobnosti“: obecně **nevypovídá** o normálním rozdělení, jak by asi chtěl, bylo by třeba použít místo vysvětlované veličiny některá z reziduí
- ▶ Nabízená „Normovaná rezidua“ jsou v regresi zcela nestandardní ( $z$ -skóry běžných reziduí)

# regrese v MS Excelu 2000, 2003

- ▶ Pozor na nabízený graf „Graf s rozdělením pravděpodobnosti“: obecně **nevypovídá** o normálním rozdělení, jak by asi chtěl, bylo by třeba použít místo vysvětlované veličiny některá z reziduí
- ▶ Nabízená „Normovaná rezidua“ jsou v regresi zcela nestandardní ( $z$ -skóry běžných reziduí)

# praktické problémy: transformace



střední délka života  $\sim$  HDP (rok 1992, 33 skupin zemí z celého světa)



- ▶ v původním měřítku závislost nelineární
- ▶ logaritmování HDP hodně pomohlo, ale ještě jistě jiné vlivy
- ▶  $\log(\text{HDP})$  vysvětlí téměř 79 % variability střední délky života
- ▶ lze identifikovat státy, které se zvlášť vymykají

# praktické problémy: transformace



střední délka života  $\sim$  HDP (rok 1992, 33 skupin zemí z celého světa)



- ▶ v původním měřítku závislost nelineární
- ▶ logaritmování HDP hodně pomohlo, ale ještě jistě jiné vlivy
- ▶  $\log(\text{HDP})$  vysvětlí téměř 79 % variability střední délky života
- ▶ lze identifikovat státy, které se zvlášť vymykají

# praktické problémy: transformace



střední délka života  $\sim$  HDP (rok 1992, 33 skupin zemí z celého světa)



- ▶ v původním měřítku závislost nelineární
- ▶ logaritmování HDP hodně pomohlo, ale ještě jistě jiné vlivy
- ▶  $\log(\text{HDP})$  vysvětlí téměř 79 % variability střední délky života
- ▶ lze identifikovat státy, které se zvlášť vymykají

# praktické problémy: transformace


střední délka života  $\sim$  HDP (rok 1992, 33 skupin zemí z celého světa)



- ▶ v původním měřítku závislost nelineární
- ▶ logaritmování HDP hodně pomohlo, ale ještě jistě jiné vlivy
- ▶  $\log(\text{HDP})$  vysvětlí téměř 79 % variability střední délky života
- ▶ lze identifikovat státy, které se zvlášť vymykají

# praktické problémy: zdánlivá závislost


počet letišť ~ délka železnic v Evropě



- ▶ v původním měřítku:  $R^2 = 78\%$ ,  $p = 0,2\%$
- ▶ v logaritmickém měřítku:  $R^2 = 66\%$ ,  $p = 0,02\%$
- ▶ logaritmické měřítko, bez Lucemburska:  $R^2 = 69\%$ ,  $p = 1\%$

# praktické problémy: zdánlivá závislost


počet letišť ~ délka železnic v Evropě



- ▶ v původním měřítku:  $R^2 = 78 \%$ ,  $p = 0,2 \%$
- ▶ v logaritmickém měřítku:  $R^2 = 66 \%$ ,  $p = 0,02 \%$
- ▶ logaritmické měřítko, bez Lucemburska:  $R^2 = 69 \%$ ,  $p = 1 \%$



# praktické problémy: zdánlivá závislost

počet letišť ~ délka železnic v Evropě





- ▶ v původním měřítku:  $R^2 = 78 \%$ ,  $p = 0,2 \%$
- ▶ v logaritmickém měřítku:  $R^2 = 66 \%$ ,  $p = 0,02 \%$
- ▶ logaritmické měřítko, bez Lucemburska:  $R^2 = 69 \%$ ,  $p = 1 \%$

# praktické problémy: zdánlivá závislost počet letišť ~ délka železnic v Evropě





- ▶ počet letišť i délka železnic souvisí s velikostí země
- ▶ u letišť:  $R^2 = 86 \%$ ,  $p = 0,03 \%$
- ▶ u železnic:  $R^2 = 64 \%$ ,  $p = 0,03 \%$

# praktické problémy: zdánlivá závislost počet letišť ~ délka železnic v Evropě





- ▶ počet letišť i délka železnic souvisí s velikostí země
- ▶ u letišť:  $R^2 = 86\%$ ,  $p = 0,03\%$
- ▶ u železnic:  $R^2 = 64\%$ ,  $p = 0,03\%$

# praktické problémy: zdánlivá závislost počet letišť ~ délka železnic v Evropě



- ▶ počet letišť i délka železnic souvisí s velikostí země
- ▶ u letišť:  $R^2 = 86\%$ ,  $p = 0,03\%$
- ▶ u železnic:  $R^2 = 64\%$ ,  $p = 0,03\%$



# praktické problémy: zdánlivá závislost počet letišť a délka železnic $\sim$ plocha



- ▶ závislost v logaritmickém měřítku:  $R^2 = 28\%$ ,  $p = 14\%$
- ▶ závislost v původním měřítku:  $R^2 = 12\%$ ,  $p = 36\%$
- ▶ relativní počet letišť nesouvisí s relativní délkou železnic



# praktické problémy: zdánlivá závislost

počet letišť a délka železnic  $\sim$  plocha



- ▶ závislost v logaritmickém měřítku:  $R^2 = 28\%$ ,  $p = 14\%$
- ▶ závislost v původním měřítku:  $R^2 = 12\%$ ,  $p = 36\%$
- ▶ relativní počet letišť nesouvisí s relativní délkou železnic




# praktické problémy: zdánlivá závislost počet letišť a délka železnic $\sim$ plocha



- ▶ závislost v logaritmickém měřítku:  $R^2 = 28\%$ ,  $p = 14\%$
- ▶ závislost v původním měřítku:  $R^2 = 12\%$ ,  $p = 36\%$
- ▶ relativní počet letišť nesouvisí s relativní délkou železnic

# praktické problémy: časová řada


vývoj HDP v ČR – pozorování tvoří časovou řadu



- ▶ po sobě jsoucí pozorování nejsou nezávislá
- ▶ je patrný vliv čtvrtletí (rezidua vpravo)
- ▶ na pravém grafu patrný vliv „balíčku“

# praktické problémy: časová řada


vývoj HDP v ČR – pozorování tvoří časovou řadu



- ▶ po sobě jsoucí pozorování nejsou nezávislá
- ▶ je patrný vliv čtvrtletí (rezidua vpravo)
- ▶ na pravém grafu patrný vliv „balíčku“

# praktické problémy: časová řada

vývoj HDP v ČR – pozorování tvoří časovou řadu



- ▶ po sobě jsoucí pozorování nejsou nezávislá
- ▶ je patrný vliv čtvrtletí (rezidua vpravo)
- ▶ na pravém grafu patrný vliv „balíčku“