

# Pravděpodobnostní metody a matematická statistika

Prof. RNDr. Gejza Dohnal, CSc.



# Pravděpodobnostní metody a matematická statistika

Prof. RNDr. Gejza Dohnal, CSc.

## XIV. Úvod do lineární regrese



<https://sms.nipax.cz/pas>

# Regresní model

# Regresní model



# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$

# Lineární regresní model


Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$

# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$






# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$


- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$



# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$


- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$



# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$


- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$



# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$



# Lineární regresní model

Lineární model:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$

# Lineární regresní model

Lineární model:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \ddots & \vdots & \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{pmatrix} \quad \vec{e} = \begin{pmatrix} e_1 \\ \vdots \\ e_n \end{pmatrix}$$

# Lineární regresní model

Lineární model:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$

$$\vec{\beta} = \begin{pmatrix} \alpha \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} \quad \mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \ddots & \vdots & \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{pmatrix} \quad \vec{e} = \begin{pmatrix} e_1 \\ \vdots \\ e_n \end{pmatrix}$$

$$\mathbf{Y} = \mathbf{X}\vec{\beta} + \vec{e}$$

# Lineární regresní model

Lineární model:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$

$$\vec{\beta} = \begin{pmatrix} \alpha \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} \quad \mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \ddots & \vdots & \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{pmatrix} \quad \vec{e} = \begin{pmatrix} e_1 \\ \vdots \\ e_n \end{pmatrix}$$

$$\mathbf{Y} = \mathbf{X}\vec{\beta} + \vec{e}$$

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - f(x_i; \alpha, \beta))^2$



# Lineární regresní model

Lineární model:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$

$$\vec{\beta} = \begin{pmatrix} \alpha \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} \quad \mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \ddots & \vdots & \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{pmatrix} \quad \vec{e} = \begin{pmatrix} e_1 \\ \vdots \\ e_n \end{pmatrix}$$

$$\mathbf{Y} = \mathbf{X}\vec{\beta} + \vec{e}$$

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - f(x_i; \alpha, \beta))^2$

v případě  $f(x_i; \alpha, \beta) = \alpha + \beta \cdot x$  :  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$

$$S = (\mathbf{Y} - \mathbf{X}\vec{\beta})'(\mathbf{Y} - \mathbf{X}\vec{\beta})$$

# Lineární regresní model

Lineární model:  $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \epsilon$

$$\vec{\beta} = \begin{pmatrix} \alpha \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} \quad \mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \ddots & \vdots & \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{pmatrix} \quad \vec{e} = \begin{pmatrix} e_1 \\ \vdots \\ e_n \end{pmatrix}$$

$$\mathbf{Y} = \mathbf{X}\vec{\beta} + \vec{e}$$

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - f(x_i; \alpha, \beta))^2$

v případě  $f(x_i; \alpha, \beta) = \alpha + \beta \cdot x$  :  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$

$$S = (\mathbf{Y} - \mathbf{X}\vec{\beta})'(\mathbf{Y} - \mathbf{X}\vec{\beta})$$



# Metoda nejmenších čtverců

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$

# Metoda nejmenších čtverců

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$

$$\frac{\partial S}{\partial \alpha} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) = 0$$

$$\frac{\partial S}{\partial \beta} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) x_i = 0$$

# Metoda nejmenších čtverců

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$

$$\frac{\partial S}{\partial \alpha} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) = 0$$

$$\frac{\partial S}{\partial \beta} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) x_i = 0$$

což vede k tzv. *normální soustavě rovnic*

$$n\alpha + \beta \sum_{i=1}^n x_i = \sum_{i=1}^n y_i$$

$$\alpha \sum_{i=1}^n x_i + \beta \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i y_i$$

# Metoda nejmenších čtverců

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$

$$\frac{\partial S}{\partial \alpha} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) = 0$$

$$\frac{\partial S}{\partial \beta} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) x_i = 0$$

což vede k tzv. *normální soustavě rovnic* a k jejímu řešení:

$$\begin{aligned} n\alpha + \beta \sum_{i=1}^n x_i &= \sum_{i=1}^n y_i & b &= \frac{\sum_{i=1}^n (x_i - \bar{x}) y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ \alpha \sum_{i=1}^n x_i + \beta \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n x_i y_i & a &= \bar{y} - b\bar{x} \end{aligned}$$

# Metoda nejmenších čtverců

Minimalizujeme ztrátovou funkci:  $S(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$

$$\frac{\partial S}{\partial \alpha} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) = 0$$

$$\frac{\partial S}{\partial \beta} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) x_i = 0$$

což vede k tzv. *normální soustavě rovnic* a k jejímu řešení:

$$\begin{aligned} n\alpha + \beta \sum_{i=1}^n x_i &= \sum_{i=1}^n y_i & b &= \frac{\sum_{i=1}^n (x_i - \bar{x}) y_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ \alpha \sum_{i=1}^n x_i + \beta \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n x_i y_i & a &= \bar{y} - b\bar{x} \end{aligned}$$



# Lineární regresní model

$$\mathbf{Y} = \mathbf{X}\vec{\beta} + \vec{e}$$

$$S = (\mathbf{Y} - \mathbf{X}\vec{\beta})'(\mathbf{Y} - \mathbf{X}\vec{\beta})$$

$$\vec{b} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

$$E\vec{b} = \vec{\beta}$$

$$\text{Var}\vec{b} = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$$

$$S_e = (\mathbf{Y} - \mathbf{X}\vec{b})'(\mathbf{Y} - \mathbf{X}\vec{b}) = \mathbf{Y}'\mathbf{Y} - \vec{b}'\mathbf{X}'\mathbf{Y}$$

$$s^2 = \frac{1}{n-k}S_e$$

## Podmínky pro použití lineárního modelu

- Nezávislost pozorování: náhodné veličiny  $Y_i$  jsou navzájem stochasticky nezávislé
- Stejné rozptyly (homoskedasticita): rozptyl vysvětlované náhodné veličiny  $Y$  nezávisí na hodnotách vysvětlující veličiny  $X$
- Normalita dat: vysvětlovaná náhodná veličina  $Y$  má normální rozdělení



# Lineární regresní model

$$\mathbf{Y} = \mathbf{X}\vec{\beta} + \vec{e}$$

$$S = (\mathbf{Y} - \mathbf{X}\vec{\beta})'(\mathbf{Y} - \mathbf{X}\vec{\beta})$$

$$\vec{b} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

$$E\vec{b} = \vec{\beta}$$

$$\text{Var}\vec{b} = \sigma^2(\mathbf{X}'\mathbf{X})^{-1}$$

$$S_e = (\mathbf{Y} - \mathbf{X}\vec{b})'(\mathbf{Y} - \mathbf{X}\vec{b}) = \mathbf{Y}'\mathbf{Y} - \vec{b}'\mathbf{X}'\mathbf{Y}$$

$$s^2 = \frac{1}{n - k} S_e$$

## Podmínky pro použití lineárního modelu

- Nezávislost pozorování: náhodné veličiny  $Y_i$  jsou navzájem stochasticky nezávislé
- Stejné rozptyly (homoskedasticita): rozptyl vysvětlované náhodné veličiny  $Y$  nezávisí na hodnotách vysvětlující veličiny  $X$
- Normalita dat: vysvětlovaná náhodná veličina  $Y$  má normální rozdělení



# Testy významnosti koeficientů regrese

**Testování významnosti koeficientů (přímkové) lineární regrese:**

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2$$

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 = \sum_{i=1}^n y_i^2 - a \sum_{i=1}^n y_i - b \sum_{i=1}^n x_i y_i$$

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 = \sum_{i=1}^n y_i^2 - a \sum_{i=1}^n y_i - b \sum_{i=1}^n x_i y_i$$

- intervalový odhad směrnice:

$$b - s_b \cdot t_{1-\gamma/2}(n-2) \leq \beta \leq b + s_b \cdot t_{1-\gamma/2}(n-2)$$

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 = \sum_{i=1}^n y_i^2 - a \sum_{i=1}^n y_i - b \sum_{i=1}^n x_i y_i$$

- intervalový odhad směrnice:

$$b - s_b \cdot t_{1-\gamma/2}(n-2) \leq \beta \leq b + s_b \cdot t_{1-\gamma/2}(n-2)$$
$$s^2 = \frac{1}{n-2} S_R \quad s_b^2 = \frac{s^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \quad s_a^2 = \frac{\sum_{i=1}^n x_i^2}{n} s_b^2$$

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 = \sum_{i=1}^n y_i^2 - a \sum_{i=1}^n y_i - b \sum_{i=1}^n x_i y_i$$

- intervalový odhad směrnice:

$$b - s_b \cdot t_{1-\gamma/2}(n-2) \leq \beta \leq b + s_b \cdot t_{1-\gamma/2}(n-2)$$
$$s^2 = \frac{1}{n-2} S_R \quad s_b^2 = \frac{s^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \quad s_a^2 = \frac{\sum_{i=1}^n x_i^2}{n} s_b^2$$

- test významnosti regresních koeficientů:

$$|T_a| = \left| \frac{a}{s_a} \right| \geq t_{1-\gamma/2}(n-2) \quad |T_b| = \left| \frac{b}{s_b} \right| \geq t_{1-\gamma/2}(n-2)$$

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

```
Regression Analysis - Linear model: Y = a + b*X
Regresní analýza - Lineární regrese
```

---

Dependent variable (Závislé proměnná): Doba opravy  
Independent variable (Nezávislé proměnná): Počet kalkulátorů

---

Parameter	Estimate Odhad	Standard Error Směrodatná odchylka	T Statistic	P-Value
Intercept (absolutní člen, b0)	-2,32215	2,56435	-0,905549	0,3786
Slope (směrnice, b1)	14,7383	0,519257	28,3834	0,0000

---

- test významnosti regresních koeficientů:

$$|T_a| = \left| \frac{a}{s_a} \right| \geq t_{1-\gamma/2}(n-2) \quad |T_b| = \left| \frac{b}{s_b} \right| \geq t_{1-\gamma/2}(n-2)$$



# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 = \sum_{i=1}^n y_i^2 - a \sum_{i=1}^n y_i - b \sum_{i=1}^n x_i y_i$$

- intervalový odhad směrnice:

$$b - s_b \cdot t_{1-\gamma/2}(n-2) \leq \beta \leq b + s_b \cdot t_{1-\gamma/2}(n-2)$$
$$s^2 = \frac{1}{n-2} S_R \quad s_b^2 = \frac{s^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \quad s_a^2 = \frac{\sum_{i=1}^n x_i^2}{n} s_b^2$$

- test významnosti regresních koeficientů:

$$|T_a| = \left| \frac{a}{s_a} \right| \geq t_{1-\gamma/2}(n-2) \quad |T_b| = \left| \frac{b}{s_b} \right| \geq t_{1-\gamma/2}(n-2)$$

- koeficient determinace  $R^2$ :

$$R^2 = \frac{\sum_{i=1}^n (a + bx_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 = \sum_{i=1}^n y_i^2 - a \sum_{i=1}^n y_i - b \sum_{i=1}^n x_i y_i$$

- intervalový odhad směrnice:

$$b - s_b \cdot t_{1-\gamma/2}(n-2) \leq \beta \leq b + s_b \cdot t_{1-\gamma/2}(n-2)$$
$$s^2 = \frac{1}{n-2} S_R \quad s_b^2 = \frac{s^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \quad s_a^2 = \frac{\sum_{i=1}^n x_i^2}{n} s_b^2$$

- test významnosti regresních koeficientů:

$$|T_a| = \left| \frac{a}{s_a} \right| \geq t_{1-\gamma/2}(n-2) \quad |T_b| = \left| \frac{b}{s_b} \right| \geq t_{1-\gamma/2}(n-2)$$

- koeficient determinace  $R^2$ :

$$R^2 = \frac{\sum_{i=1}^n (a + bx_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{S_R}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

# Testy významnosti koeficientů regrese

## Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

$$S_R = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 = \sum_{i=1}^n y_i^2 - a \sum_{i=1}^n y_i - b \sum_{i=1}^n x_i y_i$$

- intervalový odhad směrnice:

$$b - s_b \cdot t_{1-\gamma/2}(n-2) \leq \beta \leq b + s_b \cdot t_{1-\gamma/2}(n-2)$$
$$s^2 = \frac{1}{n-2} S_R \quad s_b^2 = \frac{s^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} \quad s_a^2 = \frac{\sum_{i=1}^n x_i^2}{n} s_b^2$$

- test významnosti regresních koeficientů:

$$|T_a| = \left| \frac{a}{s_a} \right| \geq t_{1-\gamma/2}(n-2) \quad |T_b| = \left| \frac{b}{s_b} \right| \geq t_{1-\gamma/2}(n-2)$$

- koeficient determinace  $R^2$ :

$$R^2 = \frac{\sum_{i=1}^n (a + bx_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{S_R}{\sum_{i=1}^n (y_i - \bar{y})^2}$$



# Testy významnosti regresního modelu

## Testování významnosti regresního modelu:

zde se testuje nulová hypotéza  $H_0: \beta_1 = \beta_2 = \dots = \beta_k$  proti alternativní hypotéze  $H_A: \beta_j \neq 0$  pro alespoň jedno  $j = 1, 2, \dots, k$ .

K tomu se používá metoda ANOVA s testovou statistikou

$$F = \frac{\frac{S_T}{k-1}}{\frac{S_R}{n-k}}$$

která má F-rozdělení s  $k-1$  a  $n-k$  stupni volnosti.

Zde

$$S_R = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \hat{y} = \mathbf{X} \cdot \vec{b}$$
$$S_T = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

# Testy významnosti regresního modelu

## Testování významnosti regresního modelu:

zde se testuje nulová hypotéza  $H_0: \beta_1 = \beta_2 = \dots = \beta_k$  proti alternativní hypotéze  $H_A: \beta_j \neq 0$  pro alespoň jedno  $j = 1, 2, \dots, k$ .

Zde

$$S_R = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \hat{y} = \mathbf{X} \cdot \vec{b}$$
$$S_T = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

# Testy významnosti regresního modelu

## Testování významnosti regresního modelu:

zde se testuje nulová hypotéza  $H_0: \beta_1 = \beta_1 = \dots = \beta_k$  proti alternativní hypotéze  $H_A: \beta_j \neq 0$  pro alespoň jedno  $j = 1, 2, \dots, k$ .

# Testy významnosti regresního modelu

## Testování významnosti regresního modelu:

zde se testuje nulová hypotéza  $H_0: \beta_1 = \beta_2 = \dots = \beta_k$  proti alternativní hypotéze  $H_A: \beta_j \neq 0$  pro alespoň jedno  $j = 1, 2, \dots, k$ .



# Testy významnosti regresního modelu

**Vyhodnocení významnosti regresního modelu:**



# Testy významnosti regresního modelu

## Vyhodnocení významnosti regresního modelu:

- Jsou-li celkový F-test i všechny t-testy statisticky významné, model se považuje za vhodný k vystižení variability proměnné  $Y$  (to však ještě neznamená, že je model správně navržen).

# Testy významnosti regresního modelu

## Vyhodnocení významnosti regresního modelu:

- Jsou-li celkový F-test i všechny t-testy statisticky významné, model se považuje za vhodný k vystižení variability proměnné  $Y$  (to však ještě neznamená, že je model správně navržen).
- Jsou-li celkový F-test i všechny t-testy statisticky nevýznamné, model se považuje za nevhodný, protože nevystihuje variabilitu proměnné  $Y$ .

# Testy významnosti regresního modelu

## Vyhodnocení významnosti regresního modelu:

- Jsou-li celkový F-test i všechny t-testy statisticky významné, model se považuje za vhodný k vystižení variability proměnné  $Y$  (to však ještě neznamená, že je model správně navržen).
- Jsou-li celkový F-test i všechny t-testy statisticky nevýznamné, model se považuje za nevhodný, protože nevystihuje variabilitu proměnné  $Y$ .
- Je-li celkový F-test statisticky významný, ale některé t-testy vychází nevýznamné, model se považuje za vhodný, ale provádí se zpravidla vypuštění nevýznamných parametrů.

# Testy významnosti regresního modelu

## Vyhodnocení významnosti regresního modelu:

- Jsou-li celkový F-test i všechny t-testy statisticky významné, model se považuje za vhodný k vystižení variability proměnné  $Y$  (to však ještě neznamená, že je model správně navržen).
- Jsou-li celkový F-test i všechny t-testy statisticky nevýznamné, model se považuje za nevhodný, protože nevystihuje variabilitu proměnné  $Y$ .
- Je-li celkový F-test statisticky významný, ale některé t-testy vychází nevýznamné, model se považuje za vhodný, ale provádí se zpravidla vypuštění nevýznamných parametrů.
- Je-li celkový F-test statisticky významný, ale všechny t-testy vychází nevýznamné – paradox: formálně model jako celek vyhovuje, ale žádný člen modelu sám o sobě významný není – jde o důsledek tzv. multikolinearity, tj. lineární závislosti mezi jednotlivými regresory.

# Testy významnosti regresního modelu

## Vyhodnocení významnosti regresního modelu:


- Jsou-li celkový F-test i všechny t-testy statisticky významné, model se považuje za vhodný k vystižení variability proměnné  $Y$  (to však ještě neznamená, že je model správně navržen).
- Jsou-li celkový F-test i všechny t-testy statisticky nevýznamné, model se považuje za nevhodný, protože nevystihuje variabilitu proměnné  $Y$ .
- Je-li celkový F-test statisticky významný, ale některé t-testy vychází nevýznamné, model se považuje za vhodný, ale provádí se zpravidla vypuštění nevýznamných parametrů.
- Je-li celkový F-test statisticky významný, ale všechny t-testy vychází nevýznamné – paradox: formálně model jako celek vyhovuje, ale žádný člen modelu sám o sobě významný není – jde o důsledek tzv. multikolinearity, tj. lineární závislosti mezi jednotlivými regresory.



# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$


- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$



# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$




# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$

pás  
spolehlivosti  
pro regresní  
přímku






# Lineární regresní model

Závislost mezi nezávisle proměnnou a závisle proměnnou:  $y=f(x)$

- funkční závislost:  $x$  a  $y$  jsou nenáhodné, pro jedno  $x$  je nejvýše jedna hodnota  $y$
- regresní závislost:  $y$  je realizace náhodné veličiny  $Y$  při konkrétním  $x$ ; pro jedno  $x$  můžeme pozorovat různé hodnoty  $Y$

pás  
spolehlivosti  
pro regresní  
přímku




# Lineární regresní model

**Pás spolehlivosti pro regresní přímku  $\hat{Y}(x) = a + bx$  :**

$$\hat{Y}(x) \pm s_{\hat{y}}(x)t_{1-\gamma/2}(n-2)$$


kde

$$s_{\hat{y}}(x) = s \cdot \sqrt{\frac{1}{n} + \frac{(x - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$




# Lineární regresní model

Pás spolehlivosti pro predikci  $\hat{Y}(x_0) = a + bx_0$  :



# Lineární regresní model

Pás spolehlivosti pro predikci  $\hat{Y}(x_0) = a + bx_0$  :




# Lineární regresní model

**Pás spolehlivosti pro predikci**  $\hat{Y}(x_0) = a + bx_0$  :

$$\hat{Y}(x_0) \pm s_{\hat{y}}(x_0)t_{1-\gamma/2}(n-2)$$

kde

$$s_{\hat{y}}(x_0) = s \cdot \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} + 1}$$



# Metoda nejmenších čtverců

**Příklad 2.4.2** *Závislost mezi teplotou  $\theta$  a rychlostí posuvu  $v$  v příkladu 2.4.1. lze považovat za regresní závislost ve tvaru  $\theta = \alpha \cdot v^\beta \cdot \epsilon$ , kde  $\alpha$  a  $\beta$  jsou regresní koeficienty a  $\epsilon$  je náhodná veličina se střední hodnotou 1. Provedeme-li transformaci  $Y = \ln\theta$ ,  $X = \ln v$ ,  $a = \ln\alpha$ ,  $e = \ln\epsilon$  a  $b = \beta$ , dostaneme  $Y = a + bX + e$ , tedy lineární vztah.*

Podobně jako v předchozím příkladu lze linearizovat i jiné modely, např. logaritmický, tj.  $Y = \ln(\alpha + \beta \cdot X)$ , reciprokový  $Y = \frac{1}{\alpha + \beta \cdot X}$  a další.

# Metoda nejmenších čtverců

**Příklad 2.4.2** *Závislost mezi teplotou  $\theta$  a rychlostí posuvu  $v$  v příkladu 2.4.1. lze považovat za regresní závislost ve tvaru  $\theta = \alpha \cdot v^\beta \cdot \epsilon$ , kde  $\alpha$  a  $\beta$  jsou regresní koeficienty a  $\epsilon$  je náhodná veličina se střední hodnotou 1. Provedeme-li transformaci  $Y = \ln\theta$ ,  $X = \ln v$ ,  $a = \ln\alpha$ ,  $e = \ln\epsilon$  a  $b = \beta$ , dostaneme  $Y = a + bX + e$ , tedy lineární vztah.*

Podobně jako v předchozím příkladu lze linearizovat i jiné modely, např. logaritmický, tj.  $Y = \ln(\alpha + \beta \cdot X)$ , reciprokový  $Y = \frac{1}{\alpha + \beta \cdot X}$  a další.



# Metoda nejmenších čtverců

Model lineární regrese lze použít i v některých případech, kdy závislost mezi veličinami  $X$  a  $Y$  není lineární. Jsou to případy, kdy lze provést takzvanou **linearizaci modelu**. Vhodnou transformací převedeme nelineární závislost na lineární a použijeme lineární regresní model. Přitom však musíme být velmi opatrní, neboť vše, co bylo odvozeno pro lineární regresní model za předpokladu normality chybového členu  $\epsilon$  platí pouze pro "linearizovaný model", nikoli pro model původní, a to opět za předpokladu, že náhodná veličina, odpovídající transformovanému chybovému členu v linearizovaném modelu, má normální rozdělení.

**Příklad 2.4.2** *Závislost mezi teplotou  $\theta$  a rychlostí posuvu  $v$  v příkladu 2.4.1. lze považovat za regresní závislost ve tvaru  $\theta = \alpha \cdot v^\beta \cdot \epsilon$ , kde  $\alpha$  a  $\beta$  jsou regresní koeficienty a  $\epsilon$  je náhodná veličina se střední hodnotou 1. Provedeme-li transformaci  $Y = \ln\theta$ ,  $X = \ln v$ ,  $a = \ln\alpha$ ,  $e = \ln\epsilon$  a  $b = \beta$ , dostaneme  $Y = a + bX + e$ , tedy lineární vztah.*

Podobně jako v předchozím příkladu lze linearizovat i jiné modely, např. logaritmický, tj.  $Y = \ln(\alpha + \beta \cdot X)$ , reciprokový  $Y = \frac{1}{\alpha + \beta \cdot X}$  a další.





## 2.4. Regresní analýza

### Regresní model experimentu

---

**lineární model pro dva faktory:**

$$Y = a + bX + cZ + dXZ + \varepsilon$$

## 2.4. Regresní analýza

### Regresní model experimentu

**lineární model pro dva faktory:**

$$Y = a + bX + cZ + dXZ + \varepsilon$$

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ \dots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_1 & Z_1 & X_1 Z_1 \\ \dots & \dots & \dots & \dots \\ 1 & X_n & Z_n & X_n Z_n \end{pmatrix} \quad \beta = \begin{pmatrix} a \\ b \\ c \\ d \end{pmatrix} \quad \epsilon = \begin{pmatrix} \epsilon_1 \\ \dots \\ \epsilon_n \end{pmatrix}$$

## 2.4. Regresní analýza

### Regresní model experimentu

**lineární model pro dva faktory:**

$$Y = a + bX + cZ + dXZ + \varepsilon$$

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ \dots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_1 & Z_1 & X_1 Z_1 \\ \dots & \dots & \dots & \dots \\ 1 & X_n & Z_n & X_n Z_n \end{pmatrix} \quad \beta = \begin{pmatrix} a \\ b \\ c \\ d \end{pmatrix} \quad \epsilon = \begin{pmatrix} \epsilon_1 \\ \dots \\ \epsilon_n \end{pmatrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} n & \sum x_i & \sum z_i & \sum x_i z_i \\ \sum x_i & \sum x_i^2 & \sum x_i z_i & \sum x_i^2 z_i \\ \sum z_i & \sum x_i z_i & \sum z_i^2 & \sum x_i z_i^2 \\ \sum x_i z_i & \sum x_i^2 z_i & \sum x_i z_i^2 & \sum x_i^2 z_i^2 \end{pmatrix} \quad \mathbf{X}'\mathbf{Y} = \begin{pmatrix} \sum Y_i \\ \sum x_i Y_i \\ \sum z_i Y_i \\ \sum x_i z_i Y_i \end{pmatrix}$$

## 2.4. Regresní analýza

### Regresní model experimentu

**lineární model pro dva faktory:**

$$Y = a + bX + cZ + dXZ + \varepsilon$$

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ \dots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & X_1 & Z_1 & X_1 Z_1 \\ \dots & \dots & \dots & \dots \\ 1 & X_n & Z_n & X_n Z_n \end{pmatrix} \quad \beta = \begin{pmatrix} a \\ b \\ c \\ d \end{pmatrix} \quad \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \dots \\ \varepsilon_n \end{pmatrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} n & \sum x_i & \sum z_i & \sum x_i z_i \\ \sum x_i & \sum x_i^2 & \sum x_i z_i & \sum x_i^2 z_i \\ \sum z_i & \sum x_i z_i & \sum z_i^2 & \sum x_i z_i^2 \\ \sum x_i z_i & \sum x_i^2 z_i & \sum x_i z_i^2 & \sum x_i^2 z_i^2 \end{pmatrix} \quad \mathbf{X}'\mathbf{Y} = \begin{pmatrix} \sum Y_i \\ \sum x_i Y_i \\ \sum z_i Y_i \\ \sum x_i z_i Y_i \end{pmatrix}$$

