

Základy stochastiky

Úvod do lineární regrese

Prof. RNDr. Gejza Dohnal, CSc.



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

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

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




pás
spolehlivosti
pro odhad

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




pás
spolehlivosti
pro odhad

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




pás
spolehlivosti
pro odhad

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



pás
spolehlivosti
pro odhad



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: $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + \epsilon$

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

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

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

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

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

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

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

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

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

Lineární regresní model

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

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

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

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

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

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

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



Metoda nejmenších čtverců

Testování významnosti koeficientů (přímkové) lineární regrese:

Metoda nejmenších čtverců

Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

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

Metoda nejmenších čtverců

Testování významnosti koeficientů (přímkové) lineární regrese:

- reziduální součet čtverců:

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

Metoda nejmenších čtverců

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:

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

Metoda nejmenších čtverců

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:

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

Metoda nejmenších čtverců

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:

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

Metoda nejmenších čtverců

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 :

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

Metoda nejmenších čtverců

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 :

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

Metoda nejmenších čtverců

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 :

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



Metoda nejmenších čtverců

Příklad 2.4.2 *Závislost mezi teplotou θ a rychlostí posuvu v v příkladu 2.4.1. lze považovat za regresní závislost ve tvaru $\theta = \alpha \cdot v^\beta \cdot \epsilon$, kde α a β jsou regresní koeficienty a ϵ 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 θ a rychlostí posuvu v v příkladu 2.4.1. lze považovat za regresní závislost ve tvaru $\theta = \alpha \cdot v^\beta \cdot \epsilon$, kde α a β jsou regresní koeficienty a ϵ 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. $Y = \ln(\alpha + \beta \cdot X)$, reciproký $Y = \frac{1}{\alpha + \beta \cdot X}$ 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 ϵ 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 θ a rychlostí posuvu v v příkladu 2.4.1. lze považovat za regresní závislost ve tvaru $\theta = \alpha \cdot v^\beta \cdot \epsilon$, kde α a β jsou regresní koeficienty a ϵ 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.

