

Úvod do praktické fyziky, cvičení 11

Metoda nejmenších čtverců – pokračování

Jan Matoušek

15. 12. 2020



UNIVERZITA KARLOVA
Matematicko-fyzikální
fakulta

Víme ze cvičení 10:

- Nechť mezi veličinou x a y platí vztah

$$y = \lambda(x|\boldsymbol{\theta}).$$

- Modelová funkce λ závisí na parametrech

$$\boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_m).$$


- V bodech x_1, x_2, \dots, x_N jsme naměřili hodnoty y_1, y_2, \dots, y_N se standardními odchylkami $\sigma_1, \sigma_2, \dots, \sigma_N$.

- $y_i \in N(\lambda(x_i|\boldsymbol{\theta}), \sigma_i)$

- Nejlepší odhad $\hat{\boldsymbol{\theta}}$ je ten, který minimalizuje χ^2

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{[y_i - \lambda(x_i|\boldsymbol{\theta})]^2}{\sigma_i^2}$$

(je to totiž ten, který maximalizuje $\ln L$).



- Zabýváme se funkcí **lineární ve svých parametrech**, tedy takovou, která jde napsat jako

$$\lambda(x|\boldsymbol{\theta}) = \theta_1 f_1(x) + \theta_2 f_2(x) + \dots + \theta_M f_M(x),$$

kde $f_i(x)$ jsou už funkce bez volných parametrů. Příklad: $a + bx + c \cos x + d\sqrt{x}$.

- Předpovědi modelu v bodech x_1, x_2, \dots, x_N můžeme zapsat pomocí matice A jako

$$\begin{pmatrix} \lambda(x_1|\boldsymbol{\theta}) \\ \lambda(x_2|\boldsymbol{\theta}) \\ \vdots \\ \lambda(x_N|\boldsymbol{\theta}) \end{pmatrix} = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \cdots & f_M(x_1) \\ f_1(x_2) & f_2(x_2) & \cdots & f_M(x_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(x_N) & f_2(x_N) & \cdots & f_M(x_N) \end{pmatrix} \begin{pmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_M \end{pmatrix}, \quad \text{neboli} \quad \lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij} \theta_j$$

- Např. pro model $\lambda(x|a, b, c) = a + bx + cx^2$ to bude

$$\begin{pmatrix} \lambda(x_1|a, b, c) \\ \vdots \\ \lambda(x_N|a, b, c) \end{pmatrix} = \begin{pmatrix} 1 & x_1 & x_1^2 \\ \vdots & \vdots & \vdots \\ 1 & x_N & x_N^2 \end{pmatrix} \begin{pmatrix} a \\ b \\ c \end{pmatrix}$$

- Zabýváme se funkcí **lineární ve svých parametrech**, tedy takovou, která jde napsat jako

$$\lambda(x|\boldsymbol{\theta}) = \theta_1 f_1(x) + \theta_2 f_2(x) + \dots + \theta_M f_M(x),$$

kde $f_i(x)$ jsou už funkce bez volných parametrů. Příklad: $a + bx + c \cos x + d\sqrt{x}$.

- Předpovědi modelu v bodech x_1, x_2, \dots, x_N můžeme zapsat pomocí matice A jako

$$\begin{pmatrix} \lambda(x_1|\boldsymbol{\theta}) \\ \lambda(x_2|\boldsymbol{\theta}) \\ \vdots \\ \lambda(x_N|\boldsymbol{\theta}) \end{pmatrix} = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \cdots & f_M(x_1) \\ f_1(x_2) & f_2(x_2) & \cdots & f_M(x_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(x_N) & f_2(x_N) & \cdots & f_M(x_N) \end{pmatrix} \begin{pmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_M \end{pmatrix}, \quad \text{neboli} \quad \lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij} \theta_j$$

- Např. pro model $\lambda(x|a, b) = a + bx + cx^2$ to bude

$$\begin{pmatrix} \lambda(x_1|a, b, c) \\ \vdots \\ \lambda(x_N|a, b, c) \end{pmatrix} = \begin{pmatrix} 1 & x_1 & x_1^2 \\ \vdots & \vdots & \vdots \\ 1 & x_N & x_N^2 \end{pmatrix} \begin{pmatrix} a \\ b \\ c \end{pmatrix}$$

- Zabýváme se funkcí **lineární ve svých parametrech**, tedy takovou, která jde napsat jako

$$\lambda(x|\boldsymbol{\theta}) = \theta_1 f_1(x) + \theta_2 f_2(x) + \dots + \theta_M f_M(x),$$

kde $f_i(x)$ jsou už funkce bez volných parametrů. Příklad: $a + bx + c \cos x + d\sqrt{x}$.

- Předpovědi modelu v bodech x_1, x_2, \dots, x_N můžeme zapsat pomocí matice A jako

$$\begin{pmatrix} \lambda(x_1|\boldsymbol{\theta}) \\ \lambda(x_2|\boldsymbol{\theta}) \\ \vdots \\ \lambda(x_N|\boldsymbol{\theta}) \end{pmatrix} = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \cdots & f_M(x_1) \\ f_1(x_2) & f_2(x_2) & \cdots & f_M(x_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(x_N) & f_2(x_N) & \cdots & f_M(x_N) \end{pmatrix} \begin{pmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_M \end{pmatrix}, \quad \text{neboli} \quad \lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij} \theta_j$$

- Např. pro model $\lambda(x|a, b) = a + bx + cx^2$ to bude

$$\begin{pmatrix} \lambda(x_1|a, b, c) \\ \vdots \\ \lambda(x_N|a, b, c) \end{pmatrix} = \begin{pmatrix} 1 & x_1 & x_1^2 \\ \vdots & \vdots & \vdots \\ 1 & x_N & x_N^2 \end{pmatrix} \begin{pmatrix} a \\ b \\ c \end{pmatrix}$$

Lineární regrese pomocí matic

- Máme lineární model $\lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij}\theta_j$.
- Potom můžeme napsat

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{[y_i - \lambda(x_i|\boldsymbol{\theta})]^2}{\sigma_i^2} = \sum_{i=1}^N \frac{[y_i - \sum_{j=1}^M A_{ij}\theta_j]^2}{\sigma_i^2}.$$

- Využijeme ještě kovarianční matice $V_{ij} = \text{cov}(y_i, y_j)$. Pro nezávislá měření je

$$V = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_N^2) \quad \text{a} \quad V^{-1} = \text{diag}\left(\frac{1}{\sigma_1^2}, \frac{1}{\sigma_2^2}, \dots, \frac{1}{\sigma_N^2}\right).$$

- Takže napíšeme

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\theta_j \right]^2.$$

- Hledáme minimum, položíme derivace rovné nule pro $k = 1, 2, \dots, M$:

$$0 = \frac{\partial \chi^2}{\partial \theta_k} = -2 \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\hat{\theta}_j \right] A_{ik} = -2 \sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i + 2 \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j$$

$$\sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i = \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j \quad \text{pro } k = 1, 2, \dots, M.$$

- To se dá zapsat maticemi (pozn.: transponovaná matice $A_{ij}^T = A_{ji}$),

$$A^T V^{-1} \mathbf{y} = A^T V^{-1} A \hat{\boldsymbol{\theta}}.$$

$$\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B \mathbf{y}.$$

Lineární regrese pomocí matic

- Máme lineární model $\lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij}\theta_j$.
- Potom můžeme napsat

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{[y_i - \lambda(x_i|\boldsymbol{\theta})]^2}{\sigma_i^2} = \sum_{i=1}^N \frac{[y_i - \sum_{j=1}^M A_{ij}\theta_j]^2}{\sigma_i^2}.$$

- Využijeme ještě kovarianční matice $V_{ij} = \text{cov}(y_i, y_j)$. Pro nezávislá měření je

$$V = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_N^2) \quad \text{a} \quad V^{-1} = \text{diag}\left(\frac{1}{\sigma_1^2}, \frac{1}{\sigma_2^2}, \dots, \frac{1}{\sigma_N^2}\right).$$

- Takže napíšeme

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\theta_j \right]^2.$$

- Hledáme minimum, položíme derivace rovné nule pro $k = 1, 2, \dots, M$:

$$0 = \frac{\partial \chi^2}{\partial \theta_k} = -2 \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\hat{\theta}_j \right] A_{ik} = -2 \sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i + 2 \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j,$$

$$\sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i = \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j \quad \text{pro } k = 1, 2, \dots, M.$$

- To se dá zapsat maticemi (pozn.: transponovaná matice $A_{ij}^T = A_{ji}$),

$$A^T V^{-1} \mathbf{y} = A^T V^{-1} A \hat{\boldsymbol{\theta}}.$$

$$\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B \mathbf{y}.$$

Lineární regrese pomocí matic

- Máme lineární model $\lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij}\theta_j$.
- Potom můžeme napsat

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{[y_i - \lambda(x_i|\boldsymbol{\theta})]^2}{\sigma_i^2} = \sum_{i=1}^N \frac{[y_i - \sum_{j=1}^M A_{ij}\theta_j]^2}{\sigma_i^2}.$$

- Využijeme ještě kovarianční matice $V_{ij} = \text{cov}(y_i, y_j)$. Pro nezávislá měření je

$$V = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_N^2) \quad \text{a} \quad V^{-1} = \text{diag}\left(\frac{1}{\sigma_1^2}, \frac{1}{\sigma_2^2}, \dots, \frac{1}{\sigma_N^2}\right).$$

- Takže napíšeme

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\theta_j \right]^2.$$

- Hledáme minimum, položíme derivace rovné nule pro $k = 1, 2, \dots, M$:

$$0 = \frac{\partial \chi^2}{\partial \theta_k} = -2 \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\hat{\theta}_j \right] A_{ik} = -2 \sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i + 2 \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j$$

$$\sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i = \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j \quad \text{pro } k = 1, 2, \dots, M.$$

- To se dá zapsat maticemi (pozn.: transponovaná matice $A_{ij}^T = A_{ji}$),

$$A^T V^{-1} \mathbf{y} = A^T V^{-1} A \hat{\boldsymbol{\theta}}.$$

$$\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B \mathbf{y}.$$

Lineární regrese pomocí matic

- Máme lineární model $\lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij}\theta_j$.
- Potom můžeme napsat

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{[y_i - \lambda(x_i|\boldsymbol{\theta})]^2}{\sigma_i^2} = \sum_{i=1}^N \frac{[y_i - \sum_{j=1}^M A_{ij}\theta_j]^2}{\sigma_i^2}.$$

- Využijeme ještě kovarianční matice $V_{ij} = \text{cov}(y_i, y_j)$. Pro nezávislá měření je

$$V = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_N^2) \quad \text{a} \quad V^{-1} = \text{diag}\left(\frac{1}{\sigma_1^2}, \frac{1}{\sigma_2^2}, \dots, \frac{1}{\sigma_N^2}\right).$$

- Takže napíšeme

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\theta_j \right]^2.$$

- Hledáme minimum, položíme derivace rovné nule pro $k = 1, 2, \dots, M$:

$$0 = \frac{\partial \chi^2}{\partial \theta_k} = -2 \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\hat{\theta}_j \right] A_{ik} = -2 \sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i + 2 \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j$$

$$\sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i = \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j \quad \text{pro } k = 1, 2, \dots, M.$$

- To se dá zapsat maticemi (pozn.: transponovaná matice $A_{ij}^T = A_{ji}$),

$$A^T V^{-1} \mathbf{y} = A^T V^{-1} A \hat{\boldsymbol{\theta}}.$$

$$\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B \mathbf{y}.$$

Lineární regrese pomocí matic

- Máme lineární model $\lambda(x_i|\boldsymbol{\theta}) = \sum_{j=1}^M A_{ij}\theta_j$.
- Potom můžeme napsat

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{[y_i - \lambda(x_i|\boldsymbol{\theta})]^2}{\sigma_i^2} = \sum_{i=1}^N \frac{[y_i - \sum_{j=1}^M A_{ij}\theta_j]^2}{\sigma_i^2}.$$

- Využijeme ještě kovarianční matice $V_{ij} = \text{cov}(y_i, y_j)$. Pro nezávislá měření je

$$V = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_N^2) \quad \text{a} \quad V^{-1} = \text{diag}\left(\frac{1}{\sigma_1^2}, \frac{1}{\sigma_2^2}, \dots, \frac{1}{\sigma_N^2}\right).$$

- Takže napíšeme

$$\chi^2(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\theta_j \right]^2.$$

- Hledáme minimum, položíme derivace rovné nule pro $k = 1, 2, \dots, M$:

$$0 = \frac{\partial \chi^2}{\partial \theta_k} = -2 \sum_{i=1}^N V_{ii}^{-1} \left[y_i - \sum_{j=1}^M A_{ij}\hat{\theta}_j \right] A_{ik} = -2 \sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i + 2 \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j$$

$$\sum_{i=1}^N A_{ik} V_{ii}^{-1} y_i = \sum_{i=1}^N \sum_{j=1}^M A_{ik} V_{ii}^{-1} A_{ij} \hat{\theta}_j \quad \text{pro } k = 1, 2, \dots, M.$$

- To se dá zapsat maticemi (pozn.: transponovaná matice $A_{ij}^T = A_{ji}$),

$$A^T V^{-1} \mathbf{y} = A^T V^{-1} A \hat{\boldsymbol{\theta}}.$$

$$\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B \mathbf{y}.$$



Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává:

$$\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B \mathbf{y}.$$

Matlab (`upf_cv11_linreg.m`, `upf_cv11_linregerr.m`)

- Příklad: fit lineární funkcí $\lambda(x|\theta_1, \theta_2) = \theta_1 + \theta_2 x$. Tedy $A = [\text{ones}(N,1), \mathbf{x}]$;
- Lineární regrese bez $\boldsymbol{\sigma}$: `theta = A \ \ y`;
- Operátor `\` provádí dělení zleva, čili řeší rovnici $\mathbf{y} = A\boldsymbol{\theta}$, pokud to lze. Pokud ne (naše A není čtvercová!), minimalizuje čtverce odchylek.
- Lineární regrese se $\boldsymbol{\sigma}$:
`invV = diag(1./sigma.^2);`
`B = A.' * invV * A \ A.' * invV;`
- `.` znamená provedení operace po složkách.
- `'` transponuje matici.





Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává:

$$\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B \mathbf{y}.$$

Matlab (`upf_cv11_linreg.m`, `upf_cv11_linregerr.m`)

- Příklad: fit lineární funkcí $\lambda(x|\theta_1, \theta_2) = \theta_1 + \theta_2 x$. Tedy $A = [\text{ones}(N,1), \mathbf{x}]$;
- Lineární regrese bez $\boldsymbol{\sigma}$: `theta = A \ \ y`;
- Operátor `\` provádí dělení zleva, čili řeší rovnici $\mathbf{y} = A\boldsymbol{\theta}$, pokud to lze. Pokud ne (naše A není čtvercová!), minimalizuje čtverce odchylek.
- Lineární regrese se $\boldsymbol{\sigma}$:
`invV = diag(1./sigma.^2);`
`B = A.' * invV * A \ A.' * invV;`
- `.` znamená provedení operace po složkách.
- `.'` transponuje matici.



Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává: $\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B\mathbf{y}$.

- Jaká je kovariance získaných parametrů?

$$\begin{aligned}\text{cov}(\hat{\theta}_i, \hat{\theta}_j) &= E\left[(\hat{\theta}_i - E[\hat{\theta}_i])(\hat{\theta}_j - E[\hat{\theta}_j])\right] = E\left[(B\mathbf{y} - E[B\mathbf{y}])_i (B\mathbf{y} - E[B\mathbf{y}])_j\right] \\ &= E\left[(B\mathbf{y} - B E[\mathbf{y}])_i (B\mathbf{y} - B E[\mathbf{y}])_j\right] = E\left[\sum_{k=1}^M B_{ik}(y_k - E[y_k]) \sum_{l=1}^M B_{jl}(y_l - E[y_l])\right] \\ &= \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} E\left[(y_l - E[y_l])(y_l - E[y_l])\right] = \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} \text{cov}(y_k, y_l).\end{aligned}$$

- Napsáno maticově,

$$U = BVB^T \quad \text{kde} \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j).$$

- `upf_cv11_linregerr.m`

Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává: $\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B\mathbf{y}$.

- Jaká je kovariance získaných parametrů?

$$\begin{aligned}\text{cov}(\hat{\theta}_i, \hat{\theta}_j) &= E\left[(\hat{\theta}_i - E[\hat{\theta}_i])(\hat{\theta}_j - E[\hat{\theta}_j])\right] = E\left[(B\mathbf{y} - E[B\mathbf{y}])_i (B\mathbf{y} - E[B\mathbf{y}])_j\right] \\ &= E\left[(B\mathbf{y} - B E[\mathbf{y}])_i (B\mathbf{y} - B E[\mathbf{y}])_j\right] = E\left[\sum_{k=1}^M B_{ik}(y_k - E[y_k]) \sum_{l=1}^M B_{jl}(y_l - E[y_l])\right] \\ &= \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} E\left[(y_l - E[y_l])(y_l - E[y_l])\right] = \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} \text{cov}(y_k, y_l).\end{aligned}$$

- Napsáno maticově,

$$U = BVB^T \quad \text{kde} \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j).$$

- `upf_cv11_linregerr.m`

Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává: $\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B\mathbf{y}$.

- Jaká je kovariance získaných parametrů?

$$\begin{aligned}\text{cov}(\hat{\theta}_i, \hat{\theta}_j) &= E\left[(\hat{\theta}_i - E[\hat{\theta}_i])(\hat{\theta}_j - E[\hat{\theta}_j])\right] = E\left[(B\mathbf{y} - E[B\mathbf{y}])_i (B\mathbf{y} - E[B\mathbf{y}])_j\right] \\ &= E\left[(B\mathbf{y} - B E[\mathbf{y}])_i (B\mathbf{y} - B E[\mathbf{y}])_j\right] = E\left[\sum_{k=1}^M B_{ik}(y_k - E[y_k]) \sum_{l=1}^M B_{jl}(y_l - E[y_l])\right] \\ &= \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} E\left[(y_l - E[y_l])(y_l - E[y_l])\right] = \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} \text{cov}(y_k, y_l).\end{aligned}$$

- Napsáno maticově,

$$U = BVB^T \quad \text{kde} \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j).$$

- `upf_cv11_linregerr.m`

Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává: $\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B\mathbf{y}$.

- Jaká je kovariance získaných parametrů?

$$\begin{aligned}\text{cov}(\hat{\theta}_i, \hat{\theta}_j) &= E\left[(\hat{\theta}_i - E[\hat{\theta}_i])(\hat{\theta}_j - E[\hat{\theta}_j])\right] = E\left[(B\mathbf{y} - E[B\mathbf{y}])_i (B\mathbf{y} - E[B\mathbf{y}])_j\right] \\ &= E\left[(B\mathbf{y} - B E[\mathbf{y}])_i (B\mathbf{y} - B E[\mathbf{y}])_j\right] = E\left[\sum_{k=1}^M B_{ik}(y_k - E[y_k]) \sum_{l=1}^M B_{jl}(y_l - E[y_l])\right] \\ &= \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} E\left[(y_l - E[y_l])(y_l - E[y_l])\right] = \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} \text{cov}(y_k, y_l).\end{aligned}$$

- Napsáno maticově,

$$U = BVB^T \quad \text{kde} \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j).$$

- `upf_cv11_linregerr.m`

Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává: $\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B\mathbf{y}$.

- Jaká je kovariance získaných parametrů?

$$\begin{aligned}\text{cov}(\hat{\theta}_i, \hat{\theta}_j) &= E\left[(\hat{\theta}_i - E[\hat{\theta}_i])(\hat{\theta}_j - E[\hat{\theta}_j])\right] = E\left[(B\mathbf{y} - E[B\mathbf{y}])_i (B\mathbf{y} - E[B\mathbf{y}])_j\right] \\ &= E\left[(B\mathbf{y} - B E[\mathbf{y}])_i (B\mathbf{y} - B E[\mathbf{y}])_j\right] = E\left[\sum_{k=1}^M B_{ik}(y_k - E[y_k]) \sum_{l=1}^M B_{jl}(y_l - E[y_l])\right] \\ &= \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} E\left[(y_l - E[y_l])(y_l - E[y_l])\right] = \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} \text{cov}(y_k, y_l).\end{aligned}$$

- Napsáno maticově,

$$U = BVB^T \quad \text{kde} \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j).$$

- `upf_cv11_linregerr.m`

Rekapitulace

- Data $\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}$ (vektory dimenze N).
- Lineární model $\lambda(x_i|\theta_1, \theta_2, \dots, \theta_M) = \sum_{j=1}^M A_{ij}\theta_j$, kde $A_{ij} = f_j(x_i)$.
- Metoda nejmenších čtverců dává: $\hat{\boldsymbol{\theta}} = (A^T V^{-1} A)^{-1} A^T V^{-1} \mathbf{y} = B\mathbf{y}$.

- Jaká je kovariance získaných parametrů?

$$\begin{aligned}\text{cov}(\hat{\theta}_i, \hat{\theta}_j) &= E\left[(\hat{\theta}_i - E[\hat{\theta}_i])(\hat{\theta}_j - E[\hat{\theta}_j])\right] = E\left[(B\mathbf{y} - E[B\mathbf{y}])_i (B\mathbf{y} - E[B\mathbf{y}])_j\right] \\ &= E\left[(B\mathbf{y} - B E[\mathbf{y}])_i (B\mathbf{y} - B E[\mathbf{y}])_j\right] = E\left[\sum_{k=1}^M B_{ik}(y_k - E[y_k]) \sum_{l=1}^M B_{jl}(y_l - E[y_l])\right] \\ &= \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} E\left[(y_l - E[y_l])(y_l - E[y_l])\right] = \sum_{k=1}^M \sum_{l=1}^M B_{ik} B_{jl} \text{cov}(y_k, y_l).\end{aligned}$$

- Napsáno maticově,

$$U = BVB^T \quad \text{kde} \quad U_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j).$$

- `upf_cv11_linregerr.m`

- Excel/Calc: viz cvičení 10.
 - Automaticky lineární regrese bez σ_i (v grafu nebo LINEST()).
 - Příklad s výpočtem parametrů fitu $a + bx$.
 - Lze udělat i obecnou regresi pomocí matic (MMULT(), MINVERSE()...)
 - Lze udělat i numerickou minimizaci χ^2 libovolné funkce (Solver).
- Gnuplot: viz cvičení 10.
 - Numerická minimizace χ^2 libovolné funkce, např.:
`fit a*x**2+b*exp(c*x) 'data.txt' using 1:2:3 via a,b,c`
- ROOT: upf_cv11_fit.cc
 - Modelová funkce: TF1 objekt – libovolná funkce [\[manuál\]](#).
 - Metoda Fit(modelFunc,options) objektu typu TGraphErrors nebo TH1 (histogram) [\[manuál\]](#).
- Python: upf_cv11_polyfit.cc, upf_cv11_fit.cc
 - Fit polynomem: `numpy.polyfit(x, y, deg=D, w=invSigmas, cov=True/False)` [\[manuál\]](#)
 - Fit obecnou funkcí (numerická minimizace):
`scipy.optimize.curve_fit(modelFunc,x,y,p0=initPars,sigma=sigmas)`
Modelová funkce je libovolná Pythonovská funkce [\[manuál\]](#).
 - Nebo další funkce jiných modulů.
- Origin: upf_cv11_origin.opju
 - Profesionální program na zpracování vědeckých dat vzdáleně podobný Excelu.