

# Úvod do praktické fyziky, cvičení 10

## Metoda nejmenších čtverců

Jan Matoušek


8. 12. 2020



UNIVERZITA KARLOVA  
Matematicko-fyzikální  
fakulta

# Jak odhadnout parametry modelu z experimentálních dat?

- Nechť mezi veličinou  $x$  a  $y$  platí vztah
$$y = \lambda(x|\theta).$$
- Modelová funkce  $\lambda$  závisí na parametrech
$$\theta = (\theta_1, \theta_2, \dots, \theta_m).$$
- V bodech  $x_1, x_2, \dots, x_N$  jsme naměřili hodnoty  $y_1, y_2, \dots, y_N$  se standardními odchylkami  $\sigma_1, \sigma_2, \dots, \sigma_N$ .
- $y_i \in N(\lambda(x_i|\theta), \sigma_i)$
- Chceme odhad  $\theta$  – fit  $\lambda(x|\theta)$  to the data.



## Odhad $\theta$ metodou maximální věrohodnosti

- Věrohodnostní funkce je součinem hustot pravděpodobnosti (zde normálních rozdělení)


$$L(\theta|x, y, \sigma) = \prod_{i=1}^N f(y_i|\lambda(x_i|\theta)) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(y_i - \lambda(x_i|\theta))^2}{2\sigma_i^2}\right]$$

$$\ln L(\theta|x, y, \sigma) = -\sum_{i=1}^N \ln(\sqrt{2\pi}\sigma_i) - \sum_{i=1}^N \frac{[y_i - \lambda(x_i|\theta)]^2}{2\sigma_i^2}$$

- Nejlepší odhad  $\hat{\theta}$  je ten, který maximalizuje  $L$  nebo ekvivalentně  $\ln L$ .

# Jak odhadnout parametry modelu z experimentálních dat?

- Nechť mezi veličinou  $x$  a  $y$  platí vztah
$$y = \lambda(x|\boldsymbol{\theta}).$$
- Modelová funkce  $\lambda$  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  $\sigma_1, \sigma_2, \dots, \sigma_N$ .
- $y_i \in N(\lambda(x_i|\boldsymbol{\theta}), \sigma_i)$
- Chceme odhad  $\boldsymbol{\theta}$  – fit  $\lambda(x|\boldsymbol{\theta})$  to the data.



## Odhad $\boldsymbol{\theta}$ metodou maximální věrohodnosti

- Věrohodnostní funkce je součinem hustot pravděpodobnosti (zde normálních rozdělení)


$$L(\boldsymbol{\theta}|x, y, \sigma) = \prod_{i=1}^N f(y_i|\lambda(x_i|\boldsymbol{\theta})) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(y_i - \lambda(x_i|\boldsymbol{\theta}))^2}{2\sigma_i^2}\right]$$

$$\ln L(\boldsymbol{\theta}|x, y, \sigma) = -\sum_{i=1}^N \ln(\sqrt{2\pi}\sigma_i) - \sum_{i=1}^N \frac{(y_i - \lambda(x_i|\boldsymbol{\theta}))^2}{2\sigma_i^2}$$

- Nejlepší odhad  $\boldsymbol{\theta}$  je ten, který maximalizuje  $L$  nebo ekvivalentně  $\ln L$ .

# Jak odhadnout parametry modelu z experimentálních dat?

- Nechť mezi veličinou  $x$  a  $y$  platí vztah
$$y = \lambda(x|\boldsymbol{\theta}).$$
- Modelová funkce  $\lambda$  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  $\sigma_1, \sigma_2, \dots, \sigma_N$ .
- $y_i \in N(\lambda(x_i|\boldsymbol{\theta}), \sigma_i)$
- Chceme odhad  $\boldsymbol{\theta}$  – fit  $\lambda(x|\boldsymbol{\theta})$  to the data.



## Odhad $\boldsymbol{\theta}$ metodou maximální věrohodnosti

- Věrohodnostní funkce je součinem hustot pravděpodobnosti (zde normálních rozdělení)


$$L(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \prod_{i=1}^N f(y_i | \lambda(x_i|\boldsymbol{\theta})) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(y_i - \lambda(x_i|\boldsymbol{\theta}))^2}{2\sigma_i^2}\right]$$

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

- Nejlepší odhad  $\hat{\boldsymbol{\theta}}$  je ten, který maximalizuje  $L$  nebo ekvivalentně  $\ln L$ .

# Jak odhadnout parametry modelu z experimentálních dat?

- Nechť mezi veličinou  $x$  a  $y$  platí vztah
$$y = \lambda(x|\boldsymbol{\theta}).$$
- Modelová funkce  $\lambda$  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  $\sigma_1, \sigma_2, \dots, \sigma_N$ .
- $y_i \in N(\lambda(x_i|\boldsymbol{\theta}), \sigma_i)$
- Chceme odhad  $\boldsymbol{\theta}$  – fit  $\lambda(x|\boldsymbol{\theta})$  to the data.



Odhad  $\boldsymbol{\theta}$  metodou maximální věrohodnosti

- Věrohodnostní funkce je součinem hustot pravděpodobnosti (zde normálních rozdělení)

$$L(\boldsymbol{\theta}|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \prod_{i=1}^N f(y_i | \lambda(x_i|\boldsymbol{\theta})) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(y_i - \lambda(x_i|\boldsymbol{\theta}))^2}{2\sigma_i^2}\right]$$

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

- Nejlepší odhad  $\hat{\boldsymbol{\theta}}$  je ten, který maximalizuje  $L$  nebo ekvivalentně  $\ln L$ .

## Metoda nejmenších čtverců



- Nejlepší odhad  $\hat{\theta}$  je ten, který maximalizuje  $L$  nebo  $\ln L$ .

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

- Maximalizace  $\ln L \Leftrightarrow$  minimalizace  $\chi^2$ , kde

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

- Minimalizace: analyticky (pro funkci  $\lambda$  lineární v  $\theta$ ) nebo numericky.



# Fit konstantní funkce $\lambda(x|a) = a$

- Vlastně stejná situace jako ve cvičení 9.
- Chi-kvadrát:

$$\chi^2(a|\mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a)^2}{\sigma_i^2}$$

- Je-li  $\hat{a}$  minimum, platí:

$$0 = \frac{\partial \chi^2}{\partial a}(\hat{a}) = -2 \sum_{i=1}^N \frac{y_i - \hat{a}}{\sigma_i^2} = -2 \sum_{i=1}^N \frac{y_i}{\sigma_i^2} + 2 \sum_{i=1}^N \frac{\hat{a}}{\sigma_i^2}.$$


- Vyjádříme  $\hat{a}$

$$\hat{a} = \frac{\sum_{i=1}^N \frac{y_i}{\sigma_i^2}}{\sum_{i=1}^N \frac{1}{\sigma_i^2}} = \frac{\langle y \rangle}{\langle 1 \rangle}, \quad \text{kde} \quad \langle g \rangle = \sum_{i=1}^N \frac{g_i}{\sigma_i^2}.$$

- Standardní odchylka – metoda přenosu chyb:

$$\frac{\partial \hat{a}}{\partial y_j} = \frac{1}{\langle 1 \rangle} \frac{1}{\sigma_j^2}$$

$$\sigma_{\hat{a}}^2 = \sum_{j=1}^N \left( \frac{\partial \hat{a}}{\partial y_j} \sigma_j \right)^2 = \sum_{j=1}^N \left( \frac{1}{\langle 1 \rangle} \frac{\sigma_j}{\sigma_j^2} \right)^2 = \frac{1}{\langle 1 \rangle}$$



# Fit konstantní funkce $\lambda(x|a) = a$

- Vlastně stejná situace jako ve cvičení 9.
- Chi-kvadrát:

$$\chi^2(a|\mathbf{y}, \sigma) = \sum_{i=1}^N \frac{(y_i - a)^2}{\sigma_i^2}$$

- Je-li  $\hat{a}$  minimum, platí:

$$0 = \frac{\partial \chi^2}{\partial a}(\hat{a}) = -2 \sum_{i=1}^N \frac{y_i - \hat{a}}{\sigma_i^2} = -2 \sum_{i=1}^N \frac{y_i}{\sigma_i^2} + 2 \sum_{i=1}^N \frac{\hat{a}}{\sigma_i^2}.$$


- Vyjádříme  $\hat{a}$

$$\hat{a} = \frac{\sum_{i=1}^N \frac{y_i}{\sigma_i^2}}{\sum_{i=1}^N \frac{1}{\sigma_i^2}} = \frac{\langle y \rangle}{\langle 1 \rangle}, \quad \text{kde} \quad \langle g \rangle = \sum_{i=1}^N \frac{g_i}{\sigma_i^2}.$$

- Standardní odchylka – metoda přenosu chyb:

$$\frac{\partial \hat{a}}{\partial y_j} = \frac{1}{\langle 1 \rangle} \frac{1}{\sigma_j^2}$$

$$\sigma_{\hat{a}}^2 = \sum_{j=1}^N \left( \frac{\partial \hat{a}}{\partial y_j} \sigma_j \right)^2 = \sum_{j=1}^N \left( \frac{1}{\langle 1 \rangle} \frac{\sigma_j}{\sigma_j^2} \right)^2 = \frac{1}{\langle 1 \rangle}$$



# Fit konstantní funkce $\lambda(x|a) = a$

- Vlastně stejná situace jako ve cvičení 9.
- Chi-kvadrát:

$$\chi^2(a|\mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a)^2}{\sigma_i^2}$$

- Je-li  $\hat{a}$  minimum, platí:


$$0 = \frac{\partial \chi^2}{\partial a}(\hat{a}) = -2 \sum_{i=1}^N \frac{y_i - \hat{a}}{\sigma_i^2} = -2 \sum_{i=1}^N \frac{y_i}{\sigma_i^2} + 2 \sum_{i=1}^N \frac{\hat{a}}{\sigma_i^2}.$$

- Vyjádříme  $\hat{a}$

$$\hat{a} = \frac{\sum_{i=1}^N \frac{y_i}{\sigma_i^2}}{\sum_{i=1}^N \frac{1}{\sigma_i^2}} = \frac{\langle y \rangle}{\langle 1 \rangle}, \quad \text{kde} \quad \langle g \rangle = \sum_{i=1}^N \frac{g_i}{\sigma_i^2}.$$

- Standardní odchylka – metoda přenosu chyb:

$$\frac{\partial \hat{a}}{\partial y_j} = \frac{1}{\langle 1 \rangle} \frac{1}{\sigma_j^2} \quad \sigma_{\hat{a}}^2 = \sum_{j=1}^N \left( \frac{\partial \hat{a}}{\partial y_j} \sigma_j \right)^2 = \sum_{j=1}^N \left( \frac{1}{\langle 1 \rangle} \frac{\sigma_j}{\sigma_j^2} \right)^2 = \frac{1}{\langle 1 \rangle}$$



# Fit přímé úměrnosti $\lambda(x|b) = bx$

- Chi-kvadrát:

$$\chi^2(b|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - bx_i)^2}{\sigma_i^2}$$

- Je-li  $\hat{b}$  minimum, platí:

$$\begin{aligned} 0 &= \frac{\partial \chi^2}{\partial b}(\hat{b}) = 2 \sum_{i=1}^N \frac{y_i - \hat{b}x_i}{\sigma_i^2} (-x_i) \\ &= -2 \sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + 2\hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2}. \end{aligned}$$


- Vyjádříme  $\hat{b}$

$$\hat{b} = \frac{\langle xy \rangle}{\langle x^2 \rangle},$$

- Standardní odchylka – metoda přenosu chyb:

$$\frac{\partial \hat{b}}{\partial y_j} = \frac{1}{\langle x^2 \rangle} \frac{x_j}{\sigma_j^2}$$

$$\sigma_{\hat{b}}^2 = \sum_{j=1}^N \left( \frac{\partial \hat{b}}{\partial y_j} \sigma_j \right)^2 = \frac{1}{\langle x^2 \rangle^2} \sum_{j=1}^N \left( \frac{x_j \sigma_j}{\sigma_j^2} \right)^2 = \frac{1}{\langle x^2 \rangle}$$



# Fit přímé úměrnosti $\lambda(x|b) = bx$

- Chi-kvadrát:

$$\chi^2(b|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - bx_i)^2}{\sigma_i^2}$$

- Je-li  $\hat{b}$  minimum, platí:

$$\begin{aligned} 0 &= \frac{\partial \chi^2}{\partial b}(\hat{b}) = 2 \sum_{i=1}^N \frac{y_i - \hat{b}x_i}{\sigma_i^2} (-x_i) \\ &= -2 \sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + 2\hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2}. \end{aligned}$$


- Vyjádříme  $\hat{b}$

$$\hat{b} = \frac{\langle xy \rangle}{\langle x^2 \rangle},$$

- Standardní odchylka – metoda přenosu chyb:

$$\frac{\partial \hat{b}}{\partial y_j} = \frac{1}{\langle x^2 \rangle} \frac{x_j}{\sigma_j^2}$$

$$\sigma_{\hat{b}}^2 = \sum_{j=1}^N \left( \frac{\partial \hat{b}}{\partial y_j} \sigma_j \right)^2 = \frac{1}{\langle x^2 \rangle^2} \sum_{j=1}^N \left( \frac{x_j \sigma_j}{\sigma_j^2} \right)^2 = \frac{1}{\langle x^2 \rangle}$$



# Fit přímé úměrnosti $\lambda(x|b) = bx$

- Chi-kvadrát:

$$\chi^2(b|\mathbf{x}, \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - bx_i)^2}{\sigma_i^2}$$

- Je-li  $\hat{b}$  minimum, platí:


$$\begin{aligned} 0 &= \frac{\partial \chi^2}{\partial b}(\hat{b}) = 2 \sum_{i=1}^N \frac{y_i - \hat{b}x_i}{\sigma_i^2} (-x_i) \\ &= -2 \sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + 2\hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2}. \end{aligned}$$

- Vyjádříme  $\hat{b}$

$$\hat{b} = \frac{\langle xy \rangle}{\langle x^2 \rangle},$$


- Standardní odchylka – metoda přenosu chyb:

$$\frac{\partial \hat{b}}{\partial y_j} = \frac{1}{\langle x^2 \rangle} \frac{x_j}{\sigma_j^2} \quad \sigma_{\hat{b}}^2 = \sum_{j=1}^N \left( \frac{\partial \hat{b}}{\partial y_j} \sigma_j \right)^2 = \frac{1}{\langle x^2 \rangle^2} \sum_{j=1}^N \left( \frac{x_j \sigma_j}{\sigma_j^2} \right)^2 = \frac{1}{\langle x^2 \rangle}$$



Fit lineární závislosti  $\lambda(x|a, b) = a + bx$

$$\chi^2(a, b | \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a - b x_i)^2}{\sigma_i^2}$$



- Takzvaná *lineární regrese*.
  - Je-li v bodě  $(\hat{a}, \hat{b})$  minimum, platí

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} = 2 \left( -\sum_{i=1}^N \frac{y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{1}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} \right)$$

$$0 = \frac{\partial \chi^2}{\partial b} = 2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} (-x_i) = 2 \left( - \sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \right)$$

# Fit lineární závislosti $\lambda(x|a,b) = a + bx$

$$\chi^2(a, b | \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a - bx_i)^2}{\sigma_i^2}$$

- Takzvaná *lineární regrese*.
- Je-li v bodě  $(\hat{a}, \hat{b})$  minimum, platí

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} = 2 \left( -\sum_{i=1}^N \frac{y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{1}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} \right)$$

$$0 = \frac{\partial \chi^2}{\partial b} = 2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} (-x_i) = 2 \left( -\sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \right)$$

- Soustavu rovnic zapíšeme přehledně pomocí  $\langle \dots \rangle$

$$\hat{a}\langle 1 \rangle + \hat{b}\langle x \rangle = \langle y \rangle$$

$$\hat{a}\langle x \rangle + \hat{b}\langle x^2 \rangle = \langle xy \rangle$$

- Vyjádříme  $\hat{a}$ :

$$\hat{a}\langle 1 \rangle \langle x^2 \rangle + \hat{b}\langle x \rangle \langle x^2 \rangle = \langle y \rangle \langle x^2 \rangle$$

$$\hat{a}\langle x \rangle \langle x \rangle + \hat{b}\langle x^2 \rangle \langle x \rangle = \langle xy \rangle \langle x \rangle$$


$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}$$

- Vyjádříme  $\hat{b}$ :

$$\hat{a}\langle 1 \rangle \langle x \rangle + \hat{b}\langle x \rangle \langle x \rangle = \langle y \rangle \langle x \rangle$$


$$\hat{a}\langle x \rangle \langle 1 \rangle + \hat{b}\langle x^2 \rangle \langle 1 \rangle = \langle xy \rangle \langle 1 \rangle$$

$$\hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle 1 \rangle \langle xy \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}$$



Fit lineární závislosti  $\lambda(x|a, b) = a + bx$

$$\chi^2(a, b | \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a - b x_i)^2}{\sigma_i^2}$$



- Takzvaná *lineární regrese*.
  - Je-li v bodě  $(\hat{a}, \hat{b})$  minimum, platí

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} = 2 \left( -\sum_{i=1}^N \frac{y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{1}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} \right)$$

$$0 = \frac{\partial \chi^2}{\partial b} = 2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} (-x_i) = 2 \left( - \sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \right)$$


- Soustavu rovnic zapíšeme přehledně pomocí  $\langle \dots \rangle$

$$\hat{a}\langle 1 \rangle + \hat{b}\langle x \rangle = \langle y \rangle$$

$$\hat{a}\langle x \rangle + \hat{b}\langle x^2 \rangle = \langle xy \rangle$$

Fit lineární závislosti  $\lambda(x|a, b) = a + bx$

$$\chi^2(a, b | \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a - b x_i)^2}{\sigma_i^2}$$



- Takzvaná *lineární regrese*.
  - Je-li v bodě  $(\hat{a}, \hat{b})$  minimum, platí

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} = 2 \left( -\sum_{i=1}^N \frac{y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{1}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} \right)$$

$$0 = \frac{\partial \chi^2}{\partial b} = 2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} (-x_i) = 2 \left( - \sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \right)$$

- Soustavu rovnic zapíšeme přehledně pomocí  $\langle \dots \rangle$

$$\hat{a}\langle 1 \rangle + \hat{b}\langle x \rangle = \langle y \rangle$$

$$\hat{a}\langle x \rangle + \hat{b}\langle x^2 \rangle = \langle xy \rangle$$


- Vyjádříme  $\hat{a}$ :

$$\hat{a}\langle 1 \rangle \langle x^2 \rangle + \hat{b}\langle x \rangle \langle x^2 \rangle = \langle y \rangle \langle x^2 \rangle$$

$$\hat{a}\langle x \rangle \langle x \rangle + \hat{b}\langle x^2 \rangle \langle x \rangle = \langle xy \rangle \langle x \rangle$$

# Fit lineární závislosti $\lambda(x|a,b) = a + bx$

$$\chi^2(a, b | \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a - bx_i)^2}{\sigma_i^2}$$



- Takzvaná *lineární regrese*.
- Je-li v bodě  $(\hat{a}, \hat{b})$  minimum, platí

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} = 2 \left( -\sum_{i=1}^N \frac{y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{1}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} \right)$$

$$0 = \frac{\partial \chi^2}{\partial b} = 2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} (-x_i) = 2 \left( -\sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \right)$$

- Soustavu rovnic zapíšeme přehledně pomocí  $\langle \dots \rangle$

$$\hat{a}\langle 1 \rangle + \hat{b}\langle x \rangle = \langle y \rangle$$

$$\hat{a}\langle x \rangle + \hat{b}\langle x^2 \rangle = \langle xy \rangle$$

- Vyjádříme  $\hat{a}$ :

$$\hat{a}\langle 1 \rangle \langle x^2 \rangle + \hat{b}\langle x \rangle \langle x^2 \rangle = \langle y \rangle \langle x^2 \rangle$$

$$\hat{a}\langle x \rangle \langle x \rangle + \hat{b}\langle x^2 \rangle \langle x \rangle = \langle xy \rangle \langle x \rangle$$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}$$

- Vyjádříme  $\hat{b}$ :


$$\hat{a}\langle 1 \rangle \langle x \rangle + \hat{b}\langle x \rangle \langle x \rangle = \langle y \rangle \langle x \rangle$$

$$\hat{a}\langle x \rangle \langle 1 \rangle + \hat{b}\langle x^2 \rangle \langle 1 \rangle = \langle xy \rangle \langle 1 \rangle$$

$$\hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle 1 \rangle \langle xy \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}$$

# Fit lineární závislosti $\lambda(x|a,b) = a + bx$

$$\chi^2(a, b | \mathbf{y}, \boldsymbol{\sigma}) = \sum_{i=1}^N \frac{(y_i - a - bx_i)^2}{\sigma_i^2}$$



- Takzvaná *lineární regrese*.
- Je-li v bodě  $(\hat{a}, \hat{b})$  minimum, platí

$$0 = \frac{\partial \chi^2}{\partial a} = -2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} = 2 \left( - \sum_{i=1}^N \frac{y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{1}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} \right)$$

$$0 = \frac{\partial \chi^2}{\partial b} = 2 \sum_{i=1}^N \frac{y_i - \hat{a} - \hat{b}x_i}{\sigma_i^2} (-x_i) = 2 \left( - \sum_{i=1}^N \frac{x_i y_i}{\sigma_i^2} + \hat{a} \sum_{i=1}^N \frac{x_i}{\sigma_i^2} + \hat{b} \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \right)$$

- Soustavu rovnic zapíšeme přehledně pomocí  $\langle \dots \rangle$

$$\hat{a}\langle 1 \rangle + \hat{b}\langle x \rangle = \langle y \rangle$$

$$\hat{a}\langle x \rangle + \hat{b}\langle x^2 \rangle = \langle xy \rangle$$

- Vyjádříme  $\hat{a}$ :

$$\hat{a}\langle 1 \rangle \langle x^2 \rangle + \hat{b}\langle x \rangle \langle x^2 \rangle = \langle y \rangle \langle x^2 \rangle$$

$$\hat{a}\langle x \rangle \langle x \rangle + \hat{b}\langle x^2 \rangle \langle x \rangle = \langle xy \rangle \langle x \rangle$$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}$$

- Vyjádříme  $\hat{b}$ :

$$\hat{a}\langle 1 \rangle \langle x \rangle + \hat{b}\langle x \rangle \langle x \rangle = \langle y \rangle \langle x \rangle$$

$$\hat{a}\langle x \rangle \langle 1 \rangle + \hat{b}\langle x^2 \rangle \langle 1 \rangle = \langle xy \rangle \langle 1 \rangle$$

$$\hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle 1 \rangle \langle xy \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}$$

Fit lineární závislosti  $\lambda(x|a,b) = a + bx$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle xy \rangle \langle 1 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}.$$

- $\hat{a}$  a  $\hat{b}$  jsou náhodné proměnné (jsou vytvořené kombinací náhodných proměnných).
- Neurčitosti (standardní odchylky) spočítáme přenosem chyb.
- Nejdřív spočítáme derivace vážených sum podle  $y_i$ :

$$\frac{\partial \langle 1 \rangle}{\partial y_i} = \frac{\partial \langle x \rangle}{\partial y_i} = \frac{\partial \langle x^2 \rangle}{\partial y_i} = 0 \quad \frac{\partial \langle y \rangle}{\partial y_i} = \frac{1}{\sigma_i^2} \quad \frac{\partial \langle xy \rangle}{\partial y_i} = \frac{x_i}{\sigma_i^2}$$

- Teď snadno určíme také derivace  $\hat{a}$  a  $\hat{b}$  podle  $y_i$ :

$$\frac{\partial \hat{a}}{\partial y_i} = \frac{\langle x \rangle \frac{x_i}{\sigma_i^2} - \langle x^2 \rangle \frac{1}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \frac{\partial \hat{b}}{\partial y_i} = \frac{\langle x \rangle \frac{1}{\sigma_i^2} - \langle 1 \rangle \frac{x_i}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle},$$

- Standardní odchylka  $\hat{a}$ :

$$\begin{aligned} \sigma_{\hat{a}}^2 &= \sum_{i=1}^N \left( \frac{\partial \hat{a}}{\partial y_i} \sigma_i \right)^2 = \frac{1}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} \sum_{i=1}^N \left( \langle x \rangle^2 \frac{x_i^2}{\sigma_i^4} - 2\langle x \rangle \langle x^2 \rangle \frac{x_i}{\sigma_i^4} + \langle x^2 \rangle^2 \frac{1}{\sigma_i^4} \right) \sigma_i^2 \\ &= \frac{\langle x \rangle^2 \langle x^2 \rangle - 2\langle x \rangle^2 \langle x^2 \rangle + \langle x^2 \rangle^2 \langle 1 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle 1 \rangle \langle x^2 \rangle^2 - \langle x \rangle^2 \langle x^2 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle x^2 \rangle (\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2)}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \end{aligned}$$

- Analogicky odvodíme pro  $\hat{b}$  a dostaneme:

$$\sigma_{\hat{b}}^2 = \frac{\langle x^2 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \quad \sigma_b^2 = \frac{\langle 1 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

Fit lineární závislosti  $\lambda(x|a,b) = a + bx$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle xy \rangle \langle 1 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}.$$

- $\hat{a}$  a  $\hat{b}$  jsou náhodné proměnné (jsou vytvořené kombinací náhodných proměnných).
- Neurčitosti (standardní odchylky) spočítáme přenosem chyb.
- Nejdřív spočítáme derivace vážených sum podle  $y_i$ :

$$\frac{\partial \langle 1 \rangle}{\partial y_i} = \frac{\partial \langle x \rangle}{\partial y_i} = \frac{\partial \langle x^2 \rangle}{\partial y_i} = 0 \quad \frac{\partial \langle y \rangle}{\partial y_i} = \frac{1}{\sigma_i^2} \quad \frac{\partial \langle xy \rangle}{\partial y_i} = \frac{x_i}{\sigma_i^2}$$

- Ted' snadno určíme také derivace  $\hat{a}$  a  $\hat{b}$  podle  $y_i$ :

$$\frac{\partial \hat{a}}{\partial y_i} = \frac{\langle x \rangle \frac{x_i}{\sigma_i^2} - \langle x^2 \rangle \frac{1}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \frac{\partial \hat{b}}{\partial y_i} = \frac{\langle x \rangle \frac{1}{\sigma_i^2} - \langle 1 \rangle \frac{x_i}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle},$$

- Standardní odchylka  $\hat{a}$ :

$$\begin{aligned} \sigma_{\hat{a}}^2 &= \sum_{i=1}^N \left( \frac{\partial \hat{a}}{\partial y_i} \sigma_i \right)^2 = \frac{1}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} \sum_{i=1}^N \left( \langle x \rangle^2 \frac{x_i^2}{\sigma_i^4} - 2\langle x \rangle \langle x^2 \rangle \frac{x_i}{\sigma_i^4} + \langle x^2 \rangle^2 \frac{1}{\sigma_i^4} \right) \sigma_i^2 \\ &= \frac{\langle x^2 \rangle \langle x^2 \rangle - 2\langle x \rangle^2 \langle x^2 \rangle + \langle x^2 \rangle^2 \langle 1 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle 1 \rangle \langle x^2 \rangle^2 - \langle x \rangle^2 \langle x^2 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle x^2 \rangle (\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2)}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \end{aligned}$$

- Analogicky odvodíme pro  $\hat{b}$  a dostaneme:

$$\sigma_{\hat{b}}^2 = \frac{\langle x^2 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \quad \sigma_{\hat{b}}^2 = \frac{\langle 1 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

Fit lineární závislosti  $\lambda(x|a,b) = a + bx$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle xy \rangle \langle 1 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}.$$

- $\hat{a}$  a  $\hat{b}$  jsou náhodné proměnné (jsou vytvořené kombinací náhodných proměnných).
- Neurčitosti (standardní odchylky) spočítáme přenosem chyb.
- Nejdřív spočítáme derivace vážených sum podle  $y_i$ :

$$\frac{\partial \langle 1 \rangle}{\partial y_i} = \frac{\partial \langle x \rangle}{\partial y_i} = \frac{\partial \langle x^2 \rangle}{\partial y_i} = 0 \quad \frac{\partial \langle y \rangle}{\partial y_i} = \frac{1}{\sigma_i^2} \quad \frac{\partial \langle xy \rangle}{\partial y_i} = \frac{x_i}{\sigma_i^2}$$

- Ted' snadno určíme také derivace  $\hat{a}$  a  $\hat{b}$  podle  $y_i$ :

$$\frac{\partial \hat{a}}{\partial y_i} = \frac{\langle x \rangle \frac{x_i}{\sigma_i^2} - \langle x^2 \rangle \frac{1}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \frac{\partial \hat{b}}{\partial y_i} = \frac{\langle x \rangle \frac{1}{\sigma_i^2} - \langle 1 \rangle \frac{x_i}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle},$$

- Standardní odchylka  $\hat{a}$ :

$$\begin{aligned} \sigma_{\hat{a}}^2 &= \sum_{i=1}^N \left( \frac{\partial \hat{a}}{\partial y_i} \sigma_i \right)^2 = \frac{1}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} \sum_{i=1}^N \left( \langle x \rangle^2 \frac{x_i^2}{\sigma_i^4} - 2\langle x \rangle \langle x^2 \rangle \frac{x_i}{\sigma_i^4} + \langle x^2 \rangle^2 \frac{1}{\sigma_i^4} \right) \sigma_i^2 \\ &= \frac{\langle x \rangle^2 \langle x^2 \rangle - 2\langle x \rangle^2 \langle x^2 \rangle + \langle x^2 \rangle^2 \langle 1 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle 1 \rangle \langle x^2 \rangle^2 - \langle x \rangle^2 \langle x^2 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle x^2 \rangle (\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2)}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \end{aligned}$$

- Analogicky odvodíme pro  $\hat{b}$  a dostaneme:

$$\sigma_{\hat{b}}^2 = \frac{\langle x^2 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \quad \sigma_b^2 = \frac{\langle 1 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

Fit lineární závislosti  $\lambda(x|a,b) = a + bx$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle xy \rangle \langle 1 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}.$$

- $\hat{a}$  a  $\hat{b}$  jsou náhodné proměnné (jsou vytvořené kombinací náhodných proměnných).
- Neurčitosti (standardní odchylky) spočítáme přenosem chyb.
- Nejdřív spočítáme derivace vážených sum podle  $y_i$ :

$$\frac{\partial \langle 1 \rangle}{\partial y_i} = \frac{\partial \langle x \rangle}{\partial y_i} = \frac{\partial \langle x^2 \rangle}{\partial y_i} = 0 \quad \frac{\partial \langle y \rangle}{\partial y_i} = \frac{1}{\sigma_i^2} \quad \frac{\partial \langle xy \rangle}{\partial y_i} = \frac{x_i}{\sigma_i^2}$$

- Ted' snadno určíme také derivace  $\hat{a}$  a  $\hat{b}$  podle  $y_i$ :

$$\frac{\partial \hat{a}}{\partial y_i} = \frac{\langle x \rangle \frac{x_i}{\sigma_i^2} - \langle x^2 \rangle \frac{1}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \frac{\partial \hat{b}}{\partial y_i} = \frac{\langle x \rangle \frac{1}{\sigma_i^2} - \langle 1 \rangle \frac{x_i}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle},$$

- Standardní odchylka  $\hat{a}$ :

$$\begin{aligned}\sigma_{\hat{a}}^2 &= \sum_{i=1}^N \left( \frac{\partial \hat{a}}{\partial y_i} \sigma_i \right)^2 = \frac{1}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} \sum_{i=1}^N \left( \langle x \rangle^2 \frac{x_i^2}{\sigma_i^4} - 2\langle x \rangle \langle x^2 \rangle \frac{x_i}{\sigma_i^4} + \langle x^2 \rangle^2 \frac{1}{\sigma_i^4} \right) \sigma_i^2 \\ &= \frac{\langle x \rangle^2 \langle x^2 \rangle - 2\langle x \rangle^2 \langle x^2 \rangle + \langle x^2 \rangle^2 \langle 1 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle 1 \rangle \langle x^2 \rangle^2 - \langle x \rangle^2 \langle x^2 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle x^2 \rangle (\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2)}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}\end{aligned}$$

- Analogicky odvodíme pro  $\hat{b}$  a dostaneme:

$$\sigma_{\hat{b}}^2 = \frac{\langle x^2 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \quad \sigma_b^2 = \frac{\langle 1 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

Fit lineární závislosti  $\lambda(x|a,b) = a + bx$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle xy \rangle \langle 1 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}.$$

- $\hat{a}$  a  $\hat{b}$  jsou náhodné proměnné (jsou vytvořené kombinací náhodných proměnných).
- Neurčitosti (standardní odchylky) spočítáme přenosem chyb.
- Nejdřív spočítáme derivace vážených sum podle  $y_i$ :

$$\frac{\partial \langle 1 \rangle}{\partial y_i} = \frac{\partial \langle x \rangle}{\partial y_i} = \frac{\partial \langle x^2 \rangle}{\partial y_i} = 0 \quad \frac{\partial \langle y \rangle}{\partial y_i} = \frac{1}{\sigma_i^2} \quad \frac{\partial \langle xy \rangle}{\partial y_i} = \frac{x_i}{\sigma_i^2}$$

- Ted' snadno určíme také derivace  $\hat{a}$  a  $\hat{b}$  podle  $y_i$ :

$$\frac{\partial \hat{a}}{\partial y_i} = \frac{\langle x \rangle \frac{x_i}{\sigma_i^2} - \langle x^2 \rangle \frac{1}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \frac{\partial \hat{b}}{\partial y_i} = \frac{\langle x \rangle \frac{1}{\sigma_i^2} - \langle 1 \rangle \frac{x_i}{\sigma_i^2}}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle},$$

- Standardní odchylka  $\hat{a}$ :

$$\begin{aligned}\sigma_{\hat{a}}^2 &= \sum_{i=1}^N \left( \frac{\partial \hat{a}}{\partial y_i} \sigma_i \right)^2 = \frac{1}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} \sum_{i=1}^N \left( \langle x \rangle^2 \frac{x_i^2}{\sigma_i^4} - 2\langle x \rangle \langle x^2 \rangle \frac{x_i}{\sigma_i^4} + \langle x^2 \rangle^2 \frac{1}{\sigma_i^4} \right) \sigma_i^2 \\ &= \frac{\langle x \rangle^2 \langle x^2 \rangle - 2\langle x \rangle^2 \langle x^2 \rangle + \langle x^2 \rangle^2 \langle 1 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle 1 \rangle \langle x^2 \rangle^2 - \langle x \rangle^2 \langle x^2 \rangle}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle x^2 \rangle (\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2)}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}\end{aligned}$$

- Analogicky odvodíme pro  $\hat{b}$  a dostaneme:

$$\sigma_{\hat{a}}^2 = \frac{\langle x^2 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \quad \sigma_{\hat{b}}^2 = \frac{\langle 1 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2}$$

Fit lineární závislosti  $\lambda(x|a,b) = a + bx$

$$\hat{a} = \frac{\langle x \rangle \langle xy \rangle - \langle y \rangle \langle x^2 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}, \quad \hat{b} = \frac{\langle x \rangle \langle y \rangle - \langle xy \rangle \langle 1 \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}.$$

- Kovarianci  $\text{cov}(\hat{a}, \hat{b})$  spočítáme podobně, jako  $\sigma$  „přenosem“ (viz Dodatky),

$$\text{cov}(A(\mathbf{x}), B(\mathbf{x})) = \sum_{i=1}^N \sum_{j=1}^N \left. \frac{\partial A}{\partial x_i} \right|_{\mu_{\mathbf{x}}} \left. \frac{\partial B}{\partial x_j} \right|_{\mu_{\mathbf{x}}} \text{cov}(x_i, x_j).$$

- Dosadíme derivace z předchozí strany a využijeme, že měření jsou nezávislá,

$$\begin{aligned} \text{cov}(\hat{a}, \hat{b}) &= \frac{1}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} \sum_{i=1}^N \left( \langle x \rangle \frac{x_i}{\sigma_i^2} - \langle x^2 \rangle \frac{1}{\sigma_i^2} \right) \left( \langle x \rangle \frac{1}{\sigma_i^2} - \langle 1 \rangle \frac{x_i}{\sigma_i^2} \right) \sigma_i^2 \\ &= \frac{1}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} \sum_{i=1}^N \left( \langle x \rangle^2 \frac{x_i}{\sigma_i^2} - \langle x \rangle \langle 1 \rangle \frac{x_i^2}{\sigma_i^2} - \langle x^2 \rangle \langle x \rangle \frac{1}{\sigma_i^2} + \langle x^2 \rangle \langle 1 \rangle \frac{x_i}{\sigma_i^2} \right) \\ &= \frac{\langle x \rangle^3 - \langle x \rangle \langle 1 \rangle \langle x^2 \rangle - \cancel{\langle x^2 \rangle \langle x \rangle \langle 1 \rangle} + \cancel{\langle x^2 \rangle \langle 1 \rangle \langle x \rangle}}{(\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle)^2} = \frac{\langle x \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle} \end{aligned}$$

- Nyní už známe standardní odchylky i kovarianci parametrů lineární závislosti:

$$\sigma_{\hat{a}}^2 = \frac{\langle x^2 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \quad \sigma_{\hat{b}}^2 = \frac{\langle 1 \rangle}{\langle 1 \rangle \langle x^2 \rangle - \langle x \rangle^2} \quad \text{cov}(\hat{a}, \hat{b}) = \frac{\langle x \rangle}{\langle x \rangle^2 - \langle 1 \rangle \langle x^2 \rangle}$$

# Dodatky: Odvození přenosu kovariance

- Funkce  $A(\mathbf{x})$  a  $B(\mathbf{x})$  approximujeme dvěma členy Taylorovy řady:

$$A(\mathbf{x}) \approx A(\boldsymbol{\mu}_{\mathbf{x}}) + \sum_{i=1}^N \frac{\partial A}{\partial x_i} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} (x_i - \mu_{x_i}) \quad B(\mathbf{x}) \approx B(\boldsymbol{\mu}_{\mathbf{x}}) + \sum_{i=1}^N \frac{\partial B}{\partial x_i} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} (x_i - \mu_{x_i})$$

- Kovariance je  $\text{cov}(A, B) = E[AB] - E[A]E[B]$  (viz lekce 7)

$$\begin{aligned} E[AB] &= E \left[ A(\boldsymbol{\mu}_{\mathbf{x}})B(\boldsymbol{\mu}_{\mathbf{x}}) + A(\boldsymbol{\mu}_{\mathbf{x}}) \sum_{i=1}^N \frac{\partial B}{\partial x_i} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} (x_i - \mu_{x_i}) + B(\boldsymbol{\mu}_{\mathbf{x}}) \sum_{i=1}^N \frac{\partial A}{\partial x_i} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} (x_i - \mu_{x_i}) \right. \\ &\quad \left. + \sum_{i=1}^N \sum_{j=1}^N \frac{\partial A}{\partial x_i} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} \frac{\partial B}{\partial x_j} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} (x_i - \mu_{x_i})(x_j - \mu_{x_j}) \right] \end{aligned}$$

- Uvědomíme si, že  $E[x_i - \mu_{x_i}] = 0$  a  $E[(x_i - \mu_{x_i})(x_j - \mu_{x_j})] = \text{cov}(x_i, x_j)$ ,

$$E[AB] = A(\boldsymbol{\mu}_{\mathbf{x}})B(\boldsymbol{\mu}_{\mathbf{x}}) + \sum_{i=1}^N \sum_{j=1}^N \frac{\partial A}{\partial x_i} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} \frac{\partial B}{\partial x_j} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} \text{cov}(x_i, x_j).$$

- Po odečtení  $E[A]E[B] = A(\boldsymbol{\mu}_{\mathbf{x}})B(\boldsymbol{\mu}_{\mathbf{x}})$  dostaneme

$$\text{cov}(A(\mathbf{x}), B(\mathbf{x})) = \sum_{i=1}^N \sum_{j=1}^N \frac{\partial A}{\partial x_i} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} \frac{\partial B}{\partial x_j} \Big|_{\boldsymbol{\mu}_{\mathbf{x}}} \text{cov}(x_i, x_j).$$