

# Metoda maximální věrohodnosti pro volbu vyhlazovacích parametrů jádrových odhadů podmíněné hustoty

Kateřina Konečná, Ivana Horová

*Ústav matematiky a statistiky, Masarykova univerzita, Brno*

ROBUST 2016  
Loučná nad Desnou, Kurzovní  
11. – 16. září 2016





# Obsah

- 1 Motivace a cíle práce
- 2 Jádrové odhady podmíněné hustoty
- 3 Dosažené výsledky práce



# Motivace a cíle práce

- motivace



# Motivace a cíle práce

## ● motivace



## ● cíle práce


- statistické vlastnosti LL odhadu
- odvození teoretické šířky vyhlazovacích parametrů
- metody pro odhad šířky vyhlazovacích parametrů
- simulační studie

# Jádrovové odhady

- jádrová funkce

# Jádrovové odhady

- jádrová funkce
- vyhlazovací parametry



# Druhy jádrových odhadů podmíněné hustoty

## Jádrový odhad podmíněné hustoty

$$\hat{f}(y|x) = \frac{1}{h_y} \sum_{i=1}^n w_i(x) K\left(\frac{y - Y_i}{h_y}\right),$$

- Nadaraya-Watsonovy váhy

$$w_i(x) = \frac{K\left(\frac{x-X_i}{h_x}\right)}{\sum_{j=1}^n K\left(\frac{x-X_j}{h_x}\right)},$$

- lokálně-lineární váhy

$$w_i(x) = \frac{(\hat{s}_2(x) - \hat{s}_1(x)(x - X_i)) K_{h_x}(x - X_i)}{n (\hat{s}_0(x)\hat{s}_2(x) - \hat{s}_1^2(x))},$$

kde  $\hat{s}_r(x) = \frac{1}{n} \sum_i (x - X_i)^r K_{h_x}(x - X_i)$

# Metody pro odhad šířky vyhlazovacích parametrů

- Metoda křížového ověřování

$$CV(h_x, h_y) = \frac{1}{n} \sum_{i=1}^n \int \hat{f}_{-i, LL}^2(y|X_i) dy - \frac{2}{n} \sum_{i=1}^n \hat{f}_{-i, LL}(y_i|X_i),$$

- Metoda maximální věrohodnosti

$$\mathcal{L}(y|x; h_x, h_y) = \prod_{j=1}^n \hat{f}_{-j, LL}(y_j|X_j).$$

# Míra kvality odhadu

- Odhad globální chyby

$$\widehat{\text{ISE}} \left\{ \hat{f}_{LL}(\cdot|\cdot) \right\} = \frac{\Delta}{n} \sum_{j=1}^N \sum_{i=1}^n \left( \hat{f}_{LL}(y_j|X_i) - f(y_j|X_i) \right)^2$$

$\mathbf{y} = (y_1, \dots, y_N)$  - vektor ekvidistantních hodnot na nosiči  $Y$   
 $\Delta$  - vzdálenost mezi sousedními hodnotami vektoru  $\mathbf{y}$ .

# Míra kvality odhadu

- Odhad globální chyby

$$\widehat{\text{ISE}} \left\{ \hat{f}_{LL}(\cdot|\cdot) \right\} = \frac{\Delta}{n} \sum_{j=1}^N \sum_{i=1}^n \left( \hat{f}_{LL}(y_j|X_i) - f(y_j|X_i) \right)^2$$

$\mathbf{y} = (y_1, \dots, y_N)$  - vektor ekvidistantních hodnot na nosiči  $Y$   
 $\Delta$  - vzdálenost mezi sousedními hodnotami vektoru  $\mathbf{y}$ .

- Logaritmus absolutní, resp. relativní chyby

$$E_1 = \ln |\widehat{\text{ISE}} - \text{ISE}_{opt}|, \text{ resp. } E_2 = \ln \left| \frac{\widehat{\text{ISE}} - \text{ISE}_{opt}}{\text{ISE}_{opt}} \right|,$$

$\text{ISE}_{opt}$  - odhad ISE pro optimální šířku vyhlazovacích parametrů.

# Dosažené výsledky práce I

- odvození rozptylu a vychýlení LL odhadu

$$\text{AV} \left\{ \hat{f}_{LL}(y|x) \right\} = \frac{1}{n^2 h_x^2 h_y} \cdot \frac{R(K) G^2(K)}{\beta_2(K)} \cdot \frac{f(y|x)}{h^2(x)},$$


$$\text{AB} \left\{ \hat{f}_{LL}(y|x) \right\} = \frac{1}{2} \beta_2(K) h_x^2 \left( \frac{\partial^2 f(y|x)}{\partial x^2} \right)^2 + \frac{1}{2} \beta_2(K) h_y^2 \left( \frac{\partial^2 f(y|x)}{\partial y^2} \right)^2$$

# Dosažené výsledky práce I

- odvození rozptylu a vychýlení LL odhadu

$$\text{AV} \left\{ \hat{f}_{LL}(y|x) \right\} = \frac{1}{n^2 h_x^2 h_y} \cdot \frac{R(K) G^2(K)}{\beta_2(K)} \cdot \frac{f(y|x)}{h^2(x)},$$

$$\text{AB} \left\{ \hat{f}_{LL}(y|x) \right\} = \frac{1}{2} \beta_2(K) h_x^2 \left( \frac{\partial^2 f(y|x)}{\partial x^2} \right)^2 + \frac{1}{2} \beta_2(K) h_y^2 \left( \frac{\partial^2 f(y|x)}{\partial y^2} \right)^2$$



# Dosažené výsledky práce II

$$\text{AMSE} \left\{ \hat{f}_{LL}(y|x) \right\} = \text{AV} \left\{ \hat{f}_{LL}(y|x) \right\} + \text{ASB} \left\{ \hat{f}_{LL}(y|x) \right\}$$

## Dosažené výsledky práce II

$$\text{AMSE} \left\{ \hat{f}_{LL}(y|x) \right\} = \text{AV} \left\{ \hat{f}_{LL}(y|x) \right\} + \text{ASB} \left\{ \hat{f}_{LL}(y|x) \right\}$$



$$\text{AMISE} \left\{ \hat{f}_{LL}(\cdot|\cdot) \right\} = \iint \text{AMSE} \left\{ \hat{f}_{LL}(y|x) \right\} h(x) \, dx \, dy$$

## Dosažené výsledky práce II

$$\text{AMSE} \left\{ \hat{f}_{LL}(y|x) \right\} = \text{AV} \left\{ \hat{f}_{LL}(y|x) \right\} + \text{ASB} \left\{ \hat{f}_{LL}(y|x) \right\}$$



$$\text{AMISE} \left\{ \hat{f}_{LL}(\cdot|\cdot) \right\} = \iint \text{AMSE} \left\{ \hat{f}_{LL}(y|x) \right\} h(x) \, dx \, dy$$



optimální šířka vyhlazovacích parametrů:  $\text{AMISE} \left\{ \hat{f}_{LL}(\cdot|\cdot) \right\} \rightarrow \min$

$$h_x^* = \left( \frac{c_1}{2n^2} \cdot \frac{1}{2c_4 z^{5/2} + c_5 z^{3/2}} \right)^{1/7}$$

$$h_y^* = h_x \sqrt{z},$$


$$\text{kde } z = \frac{\sqrt{c_5^2 + 32*c_3*c_4 - c_5}}{8c_4}$$

# Ověření metod na simulační studii

- Simulovaná data:  
 $X_i \sim N(5, 3^2)$ ,  $\varepsilon_i \sim N(0, 8^2)$ ,  
 $Y_i = 3X_i - 2 + \varepsilon_i$ ,  $i = 1, \dots, n$ .
- Počet simulovaných dat:  $n = 100$ .
- Počet opakování simulace: 100.


# Ověření metod na simulační studii

- Simulovaná data:  
 $X_i \sim N(5, 3^2)$ ,  $\varepsilon_i \sim N(0, 8^2)$ ,  
 $Y_i = 3X_i - 2 + \varepsilon_i$ ,  $i = 1, \dots, n$ .
- Počet simulovaných dat:  $n = 100$ .
- Počet opakování simulace: 100.




# Ověření metod na simulační studii

Kvalita odhadu



Vypočetní čas



# Reference

- Bashtannyk, D. M., Hyndmann, R. J. (2001). *Bandwidth Selection for Kernel Conditional Density Estimation*. Computational Statistics & Data Analysis **36**(3), 279–298
- Fan, J., Yim, T. H., *A Crossvalidation Method for Estimating Conditional Densities*, Biometrika, 2004.
- Hansen, B. E., *Nonparametric Conditional Density Estimation*, unpublished manuscript, 2004.
- Konečná K., Horová, I., Koláček J., *Conditional Density Estimations*. In C H Skiadas. Theoretical and Applied Issues in Statistics and Demography. Athens: ISAST, 2014.