

Jádrové odhady podmíněné hustoty

Kateřina Konečná, Ivanka Horová a Jan Kolářek

*Ústav matematiky a statistiky
Masarykova univerzita
Brno*

workshopy

Finanční matematika v praxi III
Matematické modely a aplikace

Podlesí

3. – 6. září 2013



evropský
sociální
fond v ČR



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání
pro konkurenceschopnost





AMathNet
sít' pro transfer znalostí v aplikované matematice

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ


Obsah

- 1 Jádrové odhady podmíněné hustoty
- 2 Míra kvality a volba vyhlazovacích parametrů
- 3 Aplikace na reálná data
- 4 Literatura



Motivace



Konstrukce jádrových odhadů podmíněné hustoty



Konstrukce jádrových odhadů podmíněné hustoty



Jádro

Definition

Reálná funkce K splňující


- 1 $K \in Lip[-1, 1]$, tj. $|K(x) - K(y)| \leq L|x - y|$, $\forall x, y \in [-1, 1]$, $L > 0$,
- 2 $supp(K) = [-1, 1]$,
- 3 momentové podmínky:

$$\int_{-1}^1 x^j K(x) dx = \begin{cases} 1 & j = 0, \\ 0 & j = 1, \\ \beta_2 \neq 0 & j = 2 \end{cases}$$


se nazývá jádro řádu 2.

Jádro

Epanechnikov kernel



Gaussian kernel



Podmíněná hustota

Nechť $X \in \mathbb{R}$ je náhodná veličina a $h(x)$ její hustota, $Y \in \mathbb{R}$ náhodná veličina a $f(x, y)$ sdružená hustota náhodného vektoru (X, Y) .

Podmíněná hustota $Y|(X = x)$ je definována

$$f(y|x) = \frac{f(x, y)}{h(x)}.$$

Jádrový odhad marginální hustoty:

$$\hat{h}(x) = \frac{1}{nh_x} \sum_{i=1}^n K\left(\frac{x - X_i}{h_x}\right) \quad (1)$$

Jádrový odhad sdružené hustoty:

$$\hat{f}(x, y) = \frac{1}{nh_x h_y} \sum_{i=1}^n K\left(\frac{x - X_i}{h_x}\right) K\left(\frac{y - Y_i}{h_y}\right) \quad (2)$$

Nadaraya-Watsonův odhad podmíněné hustoty

Jádrový odhad podmíněné hustoty náhodné veličiny $Y|(X = x)$ je definován

$$\hat{f}_{NW}(y|x) = \frac{1}{h_y} \sum_{i=1}^n w_i(x) K\left(\frac{y - Y_i}{h_y}\right), \quad (3)$$

kde

$$w_i(x) = \frac{K\left(\frac{x - X_i}{h_x}\right)}{\sum_{j=1}^n K\left(\frac{x - X_j}{h_x}\right)} \quad (4)$$

je váhová funkce.

Odhad se nazývá Nadaraya-Watsonův odhad podmíněné hustoty.


Míra kvality odhadu $\hat{f}(y|x)$

- vyhlazovací matice $\mathbf{H} = \begin{pmatrix} h_x & 0 \\ 0 & h_y \end{pmatrix}$
- vyhlazovací parametry h_x, h_y určují vyhlazení ve směru x a y


Míra kvality odhadu $\hat{f}(y|x)$

- vyhlazovací matice $\mathbf{H} = \begin{pmatrix} h_x & 0 \\ 0 & h_y \end{pmatrix}$
- vyhlazovací parametry h_x, h_y určují vyhlazení ve směru x a y


Oversmoothing



Optimal



Undersmoothing



Míra kvality odhadu $\hat{f}(y|x)$

- MISE: **M**ean **I**ntegrated **S**quare **E**rror

$$\text{MISE} \{ \hat{f}(y|x) \} = \iint \text{E} \{ \hat{f}(y|x) - f(y|x) \}^2 h(x) dx dy$$

- AMISE: **A**symptotic **M**ean **I**ntegrated **S**quare **E**rror

$$\text{AMISE} \{ \hat{f}_{NW}(y|x) \} = \frac{c_1}{nh_x h_y} - \frac{c_2}{nh_x} + c_3 h_x^4 + c_4 h_y^4 + c_5 h_x^2 h_y^2$$

- optimální šířka vyhlazovacích parametrů:

$$(h_x, h_y) = \arg \min_{(h_x, h_y) \in H} \text{AMISE}$$

Metody volby vyhlazovacích parametrů

- metody kombinující metody pro odhad parametrů regrese a hustoty
 - pro hustotu: cross-validace, metoda referenční hustoty
 - pro regresi: cross-validace, metoda penalizačních funkcí
- metoda referenční hustoty
 - předpoklad normálního rozložení podmíněné hustoty

$$f(y|x) = \frac{1}{\sqrt{2\pi}(p + qx)} e^{-\frac{1}{2} \left(\frac{y-a-bx}{p+qx} \right)^2}.$$

- předpoklad normální nebo rovnoměrně spojité marginální hustoty
- cross-validace
 - $CV(h_x, h_y) = \frac{1}{n} \sum_{i=1}^n \int \hat{f}_{-i}(y|X_i)^2 dy - \frac{2}{n} \sum_{i=1}^n \hat{f}_{-i}(Y_i|X_i)$
- metoda penalizačních funkcí
- bootstrap

Iterační metoda

- vyhlazovací parametry dány minimalizací

$$\text{AMISE} \left\{ \hat{f}(y|x) \right\} = \text{AIV} \left\{ \hat{f}(y|x) \right\} + \text{AISB} \left\{ \hat{f}(y|x) \right\}$$

- namísto vztahu

$$\text{AIV} \left\{ \hat{f}(y|x) \right\} = 2\text{AISB} \left\{ \hat{f}(y|x) \right\} \quad (5)$$

závisejícího na neznámé hustotě budeme uvažovat

$$\widehat{\text{AIV}} \left\{ \hat{f}(y|x) \right\} = 2\widehat{\text{ISB}} \left\{ \hat{f}(y|x) \right\} \quad (6)$$

Iterační metoda

$$\widehat{\text{AIV}} \left\{ \hat{f}(y|x) \right\} = 2 \widehat{\text{ISB}} \left\{ \hat{f}(y|x) \right\}, \text{ kde}$$

$$\widehat{\text{AIV}} \left\{ \hat{f}(y|x) \right\} = \frac{c_1}{nh_x h_y}, \quad c_1 = \int R^2(K) \, dx \quad \text{a} \quad R(K) = \int K^2(x) \, dx$$


$$\widehat{\text{ISB}} \left\{ \hat{f}(y|x) \right\} = \iint \left\{ \frac{1}{h_y} \frac{\sum_i (K * K) \left(\frac{x-X_i}{h_x} \right) (K * K) \left(\frac{y-Y_i}{h_y} \right)}{\sum_i (K * K) \left(\frac{x-X_i}{h_x} \right)} - \frac{1}{h_y} \frac{\sum_i K \left(\frac{x-X_i}{h_x} \right) K \left(\frac{y-Y_i}{h_y} \right)}{\sum_i K \left(\frac{x-X_i}{h_x} \right)} \right\}^2 h(x) \, dx \, dy$$

Iterační metoda

- systém dvou nelineárních rovnic:


$$\widehat{AIV}(\hat{h}_x, \hat{h}_y) = 2\widehat{ISB}(\hat{h}_x, \hat{h}_y)$$

$$\hat{h}_y = \hat{c}\hat{h}_x$$



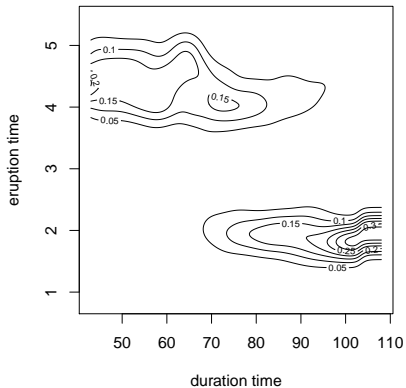
Reálná data: gejzír Old Faithful

- 299 pozorování erupcí gejzíru Old Faithful, Yellowstonský národní park, Wyoming, USA, 1989 – 1990
- 2 proměnné:
 - nezávislá proměnná: doba čekání do následující erupce [min]
 - závislá proměnná: doba erupce [min]




Gejzír Old Faithful

Iterative method




Cross-validation method




Old Faithful geyser

Iterative method



Cross-validation method



Literatura

- BASHTANNYK, D. M., HYNDMANN, R. J. *Bandwidth Selection for Kernel Conditional Density Estimation*. Computational Statistics & Data Analysis, 2001, Volume 36, Issue 3, Pages 279–298
- DE GOOIJER, J. G., ZEROM, D. *On Conditional Density Estimation*. Statistica Neerlandica, Netherlands Society for Statistics and Operations Research, 2003, Volume 57, Issue 2, Pages 159–176
- HANSEN, B. E. *Nonparametric Conditional Density Estimation*. 2004. [online][cit. leden 2012]. Dostupné z:
<http://www.ssc.wisc.edu/~bhansen/papers/ncde.pdf>
- HYNDMAN, R. J., BASHTANNYK, D. M., GRUNWALD, G. K. *Estimating and Visualising Conditional Densities*. Journal of Computational and Graphical Statistics, 1996, Volume 5, Number 4, Pages 315–336

Děkuji za pozornost.