

Metody odhadu šířky vyhlazovacích parametrů Priestley-Chaova odhadu podmíněné hustoty

Kateřina Konečná

Ústav matematiky a statistiky, Masarykova univerzita, Brno

Ústav matematiky a deskriptivní geometrie, Vysoké učení technické v Brně, Brno


ROBUST 2018
rekreační zařízení Rybník
21. – 26. ledna 2018

Obsah


- 1 Motivace
- 2 Jádrové odhady podmíněné hustoty
- 3 Priestley-Chaův odhad podmíněné hustoty
- 4 Metody pro odhad šířky vyhlazovacích parametrů
- 5 Simulační studie
- 6 Dosažené výsledky práce

Motivace



Geyser data



Motivace



Motivace



Cíle práce

- Priestley-Chaův odhad podmíněné hustoty
- statistické vlastnosti odhadu
- optimální šířky vyhlazovacích parametrů
- metody pro odhad šířky vyhlazovacích parametrů
- simulační studie

Jádrová funkce

Definice

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.

Typy odhadů

- jádrový odhad podmíněné hustoty

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

Typy odhadů

- jádrový odhad podmíněné hustoty

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

- Nadaraya-Watsonovy váhy

$$w_i(x) = \frac{K_{h_x}(x-X_i)}{\sum_{j=1}^n K_{h_x}(x-X_j)}$$

- lokálně lineární váhy

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

- Priestley-Chaovy váhy

$$w_i(x) = \frac{1}{n} K_{h_x}(x - X_i)$$

Statistické vlastnosti odhadu

Věta

Nechť Y_1, Y_2, \dots, Y_n jsou pozorované hodnoty v bodech plánu $x_i = \frac{i}{n}$, $i = 1, 2, \dots, n$ a $\delta = x_{i+1} - x_i$, $i = 1, 2, \dots, n-1$. Nechť je $f(y|x)$ nejméně 2krát spojité diferencovatelná a $K(x)$ jádrová funkce splňující momentové podmínky. Pro $h_x \rightarrow 0$, $h_y \rightarrow 0$ a $nh_x h_y \rightarrow \infty$ pro $n \rightarrow \infty$ jsou asymptotické vychýlení (AB) a asymptotický rozptyl (AV) rovny

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

$$\text{AV} \left\{ \hat{f}_{PC}(y|x) \right\} = \frac{\delta}{h_x h_y} R^2(K) f(y|x), \quad (2)$$

kde $R(K) = \int K^2(u) du$.

Míry kvality odhadu

- Asymptotická střední kvadratická chyba (**lokální chyba odhadu**):

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

- Asymptotická střední integrální kvadratická chyba (**globální chyba odhadu**):

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

- Optimální šířky vyhlazovacích parametrů:

$$h_x^* = \delta^{1/6} c_1^{1/6} \left(4 \left(\frac{c_2^5}{c_3} \right)^{1/4} + 2c_4 \left(\frac{c_2}{c_3} \right)^{3/4} \right)^{-1/6} \quad (3)$$

$$h_y^* = \left(\frac{c_2}{c_3} \right)^{1/4} h_x^*.$$

Metoda křížového ověřování

- Hlavní myšlenka: minimalizace integrální kvadratické chyby (ISE).
- Cross-validační funkce $CV(h_x, h_y)$ je vhodným odhadem ISE:

$$CV(h_x, h_y) = \delta^2 \sum_i \sum_{j \neq i} h_x h_y K_{h_x \sqrt{2}}(x_i - x_j) K_{h_y \sqrt{2}}(Y_i - Y_j) \\ - 2\delta \sum_i \hat{f}_{-i, PC}(Y_i | x_i),$$

kde $\hat{f}_{-i, PC}(y|x)$ je odhad v bodě (x_i, Y_i) s využitím bodů $\{(x_j, Y_j), j \neq i\}$.

- Odhadы vyhlazovacích parametrů:

$$(\hat{h}_x, \hat{h}_y)_{CV} = \arg \min_{(h_x, h_y)} CV(h_x, h_y).$$

Metoda referenční hustoty

- Motivace: předpoklad rozdělení pravděpodobnosti pro náhodné veličiny X a $Y|X=x$)
- Hlavní myšlenka:

$$Y|(X=x) \sim N(c + dx, p^2),$$

pro $d \neq 0, p > 0$.

- Numerický výpočet (2D lichoběžníkové pravidlo) konstant $c_1, c_2, c_3, c_4 \rightarrow$ dosazením do (3) dostáváme $(\hat{h}_x, \hat{h}_y)_{REF}$

Simulační studie

zvolený model, generování simulovaných hodnot



odhad šířek vyhlazovacích parametrů \hat{h}_x , \hat{h}_y , metody: CV, REF



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

kde $\mathbf{y} = (y_1, \dots, y_N)$ - vektor ekvidistantních hodnot na nosiči rozdělení pravděpodobnosti náhodné veličiny Y , $\Delta = |y_{j+1} - y_j|$, $j = 1, \dots, N - 1$



opakování 200krát → porovnání:

Simulační studie

zvolený model, generování simulovaných hodnot



odhad šířek vyhlazovacích parametrů \hat{h}_x , \hat{h}_y , metody: CV, REF



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

kde $\mathbf{y} = (y_1, \dots, y_N)$ - vektor ekvidistantních hodnot na nosiči rozdělení pravděpodobnosti náhodné veličiny Y , $\Delta = |y_{j+1} - y_j|$, $j = 1, \dots, N - 1$



opakování 200krát → porovnání:

- (A) \hat{h}_x , (B) \hat{h}_y , (C) $\widehat{\text{ISE}}$, (D) výpočetní čas


Simulace 1

- model: $x_i = \frac{i}{n}$, $\varepsilon_i \sim N(0, 1)$, $Y_i = 3x_i - 2 + \varepsilon_i$, $i = 1, \dots, 100$


Simulace 1

- model: $x_i = \frac{i}{n}$, $\varepsilon_i \sim N(0, 1)$, $Y_i = 3x_i - 2 + \varepsilon_i$, $i = 1, \dots, 100$


(A)



(B)




(C)



(D) výpočetní čas [s]

	CV	REF
průměr	118.102	0.005
medián	119.115	0
sm. odchylka	4.062	0.008
IQR	1.163	0.01

Simulace 1




Simulace 2

- model: $x_i = \frac{i}{n}$, $\varepsilon_i \sim N(0, 0.5^2)$, $Y_i = e^{x_i} + \varepsilon_i$, $i = 1, \dots, 100$


Simulace 2

- model: $x_i = \frac{i}{n}$, $\varepsilon_i \sim N(0, 0.5^2)$, $Y_i = e^{x_i} + \varepsilon_i$, $i = 1, \dots, 100$


(A)



(B)




(C)



(D) výpočetní čas [s]

	CV	REF
průměr	110.775	0.005
medián	110.79	0
sm. odchylka	0.980	0.008
IQR	0.685	0.01

Simulace 2



Dosažené výsledky práce


Priestley-Chaův odhad podmíněné hustoty:

- statistické vlastnosti odhadu (střední hodnota, rozptyl)
- míry kvality odhadu (lokální, globální)
- optimální šířky vyhlazovacích parametrů \hat{h}_x^* , \hat{h}_y^*
- metody pro odhad šířky vyhlazovacích parametrů:
 - metoda křížového ověřování
 - metoda referenční hustoty
 - leave-one-out metoda maximální věrohodnosti

Budoucí práce

- Co dělat v případě dat s nelineární podmíněnou střední hodnotou?

$$x_i = \frac{i}{n}, \quad \varepsilon_i \sim N(0, 1), \quad Y_i = \sin(3\pi x_i^2) + \varepsilon_i, \quad i = 1, \dots, 100$$



- Další metody pro odhad šířky vyhlazovacích parametrů:
 - odvození vztahů pro metodu referenční hustoty
 - iterační metoda

Reference

- BASHTANNYK, D. M., HYNDMAN, R. J., Bandwidth selection for kernel conditional density estimation. *Computational Statistics & Data Analysis*, vol. 36, no. 3, 2001: pp. 279–298, ISSN 0167-9473.
- KONEČNÁ, K., Priestley-chao estimator of conditional density, In *Mathematics, Information Technologies and Applied Sciences 2017, post-conference proceedings of extended versions of selected papers*, Brno: University of Defence, 2017, ISBN 978-80-7582-026-6, pp. 151–163.
- PRIESTLEY, M. B., CHAO, M. T., Non-parametric function fitting. *Journal of the Royal Statistical Society. Series B (Methodological)*, vol. 34, no. 3, 1972: pp. 385–392, ISSN 00359246.
- ROSENBLATT, M., Conditional probability density and regression estimators. *Multivariate analysis II*, vol. 25, 1969: p. 31.
- WAND, M. P., JONES, M. C., *Kernel smoothing*. Crc Press, 1994, ISBN 9780412552700.

Optimální šířky vyhlazovacích parametrů

AMISE $\left\{ \hat{f}_{PC}(\cdot|\cdot) \right\} = \frac{\delta}{h_x h_y} c_1 + c_2 h_x^4 + c_3 h_y^4 + c_4 h_x^2 h_y^2$, kde

$$c_1 = \int R^2(K) dx,$$

$$c_2 = \frac{1}{4} \beta_2^2(K) \iint \left(\frac{\partial^2 f(y|x)}{\partial x^2} \right)^2 dx dy,$$

$$c_3 = \frac{1}{4} \beta_2^2(K) \iint \left(\frac{\partial^2 f(y|x)}{\partial y^2} \right)^2 dx dy,$$

$$c_4 = \frac{1}{2} \beta_2^2(K) \iint \frac{\partial^2 f(y|x)}{\partial x^2} \frac{\partial^2 f(y|x)}{\partial y^2} dx dy.$$