

Kapitola 5

Jádrové odhady dvourozměrných hustot

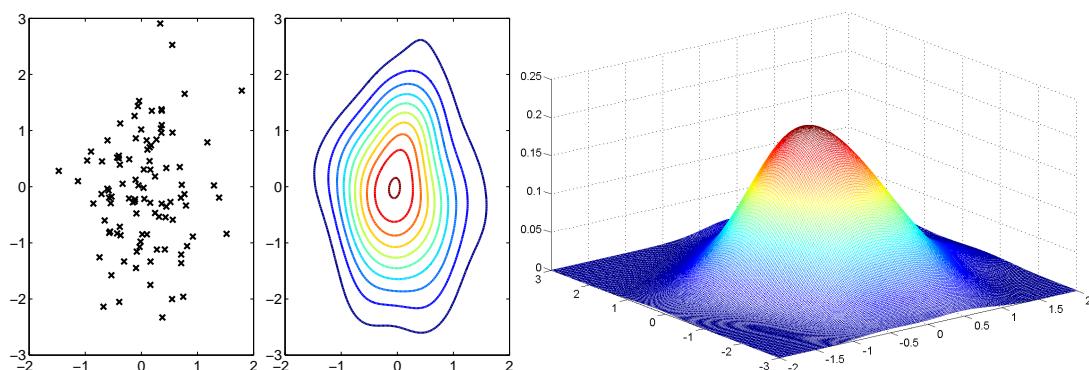
Výstupy z výukové jednotky

Student

- bude znát součinová a sférická dvourozměrná jádra pro odhadu dvourozměrných hustot.
- porozumí principu vyhlazování dvourozměrných hustot.
- pochopí nejjednodušší metody pro volbu prvků diagonální vyhlazovací matice.
- zvládne použití příslušného toolboxu v Matlabu pro simulační studii i pro zpracování reálných dat.

1 Motivace

V této kapitole se budeme zabývat rozšířením jádrových odhadů pro jednorozměrné hustoty na odhad vícerozměrných hustot. Ovšem ve vícerozměrném případě nevystačíme s jedním vyhlazovacím parametrem, ale je třeba specifikovat matici vyhlazovacích parametrů. Tato matice řídí jak hladkost, tak i orientaci vícerozměrného vyhlazení. Budeme se zabývat jádrovým odhadem, který je přímým rozšířením jednorozměrného odhadu (3.1) v kapitole 3, a zaměříme se zejména na odhad dvourozměrné hustoty.



Obrázek 5.1: Náhodný výběr a jeho jádrový odhad

Poznámka 1.1. Jádrové odhady dvourozměrných hustot se obvykle znázorňují pomocí vrstevnic, které umožňují snazší náhled na odhadnutou funkci.

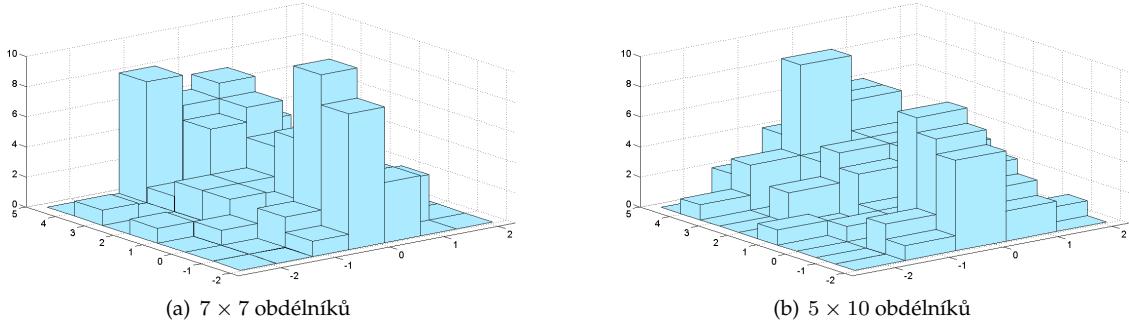
2 Základní typy odhadů

Podobně jako u odhadů hustoty můžeme použít *histogram*, ale ten má zmíněné nevýhody – jde o schodovitou funkci a je citlivý na volbu počtu a šířky třídicích obdélníků – viz obrázek 5.2.

Příklad 2.1. Mějme dán datový soubor o velikosti $n = 100$ generovaný ze směsi tří normálních hustot¹. $N(0, -1; 1/3, 1/3, 0)$, $N(0, 2; 1, 1, 0)$ a $N(0, 4; 1/3, 1/3, 0)$

$$f(x, y) = \frac{1}{3} \frac{3}{2\pi} e^{-\frac{3}{2}(x^2 + (y+1)^2)} + \frac{1}{3} \frac{1}{2\pi} e^{-\frac{1}{2}(x^2 + (y-2)^2)} + \frac{1}{3} \frac{3}{2\pi} e^{-\frac{3}{2}(x^2 + (y-4)^2)}$$

(Data jsou v tabulce 6.4.) Z obrázku 5.2 je patrné, že histogram nepostihuje charakteristické rysy hustoty pravděpodobnosti dat.



Obrázek 5.2: Histogramy s různými počty třídicích obdélníků

Předpokládejme, že máme k dispozici náhodný výběr $([X_1, Y_1], \dots, [X_n, Y_n])$ z dvourozměrného spojitého rozdělení s hustotou $f(x, y)$. Jádrový odhad hustoty f v bodě $[x, y] \in \mathbb{R}^2$ je definovaný vztahem

$$\hat{f}(x, y; \mathbf{H}) = \frac{1}{n} \sum_{i=1}^n K_{\mathbf{H}}(x - X_i, y - Y_i), = \frac{1}{n|\mathbf{H}|} \sum_{i=1}^n K\left(\mathbf{H}^{-1}(x - X_i, y - Y_i)^T\right) \quad (5.1)$$

přičemž \mathbf{H} je matice vyhlazovacích parametrů a K je dvourozměrné jádro.

Jádro K je dvourozměrná funkce, kterou můžeme získat pomocí jednorozměrného symetrického jádra K_1 ($K_1 \in S_{02}$). Existují dva typy těchto jader:

- součinové jádro $K^P(x, y) = K_1(x) \cdot K_1(y)$,
- sféricky symetrické jádro $K^S(x, y) = c_k^{-1} K_1(\sqrt{x^2 + y^2})$, $c_k = \iint K_1(\sqrt{x^2 + y^2}) dx dy$.

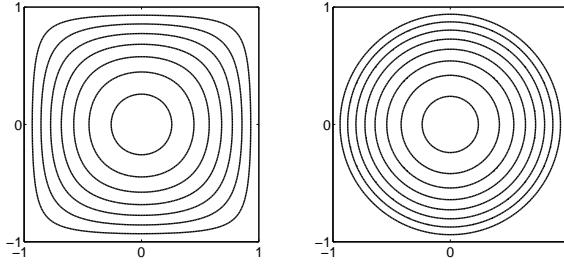
Příklad 2.2. Epanečníkovo jádro, které je v jednorozměrném případě tvaru $K(x) = \frac{3}{4}(1-x^2)I_{[-1,1]}(x)$, má následující dvourozměrné varianty

$$K^P(x, y) = \frac{9}{16}(1-x^2)(1-y^2) \quad \text{pro} \quad -1 \leq x, y \leq 1,$$

$$K^S(x, y) = \frac{2}{\pi}(1-x^2-y^2) \quad \text{pro} \quad x^2 + y^2 \leq 1.$$

Na obrázku 5.3 jsou zobrazeny vrstevnice těchto jader.

¹Používáme zde zkrácený zápis pro dvourozměrnou hustotu normálního rozdělení, a to $N(\mu_1, \mu_2; \sigma_1^2, \sigma_2^2, \varrho)$



Obrázek 5.3: Součinové (vlevo) a sféricky symetrické (vpravo) dvourozměrné Epanečníkovo jádro

Podívejme se blíže na matici \mathbf{H} . Jde o matici vyhlazovacích parametrů, které řídí hladkosť výsledného odhadu. Navíc také udávají orientaci odhadnuté hustoty. Rozlišujeme tři základní třídy vyhlazovacích matic:

- třída \mathcal{S} , která obsahuje matice s jediným vyhlazovacím parametrem,
- třída \mathcal{D} , která zahrnuje diagonální matice,
- třída \mathcal{F} , která obsahuje tzv. plné matice.

Rozdíly mezi jednotlivými maticemi jsou patrné z tabulky 5.1, kde jsou zobrazeny vrstevnice součinového Epanečníkova jádra v závislosti na třídě matic.

Tabulka 5.1: Třídy vyhlazovacích matic

\mathcal{S}	\mathcal{D}	\mathcal{F}
$\begin{pmatrix} h^2 & 0 \\ 0 & h^2 \end{pmatrix}$	$\begin{pmatrix} h_1^2 & 0 \\ 0 & h_2^2 \end{pmatrix}$	$\begin{pmatrix} h_1^2 & h_{12} \\ h_{12} & h_2^2 \end{pmatrix}$

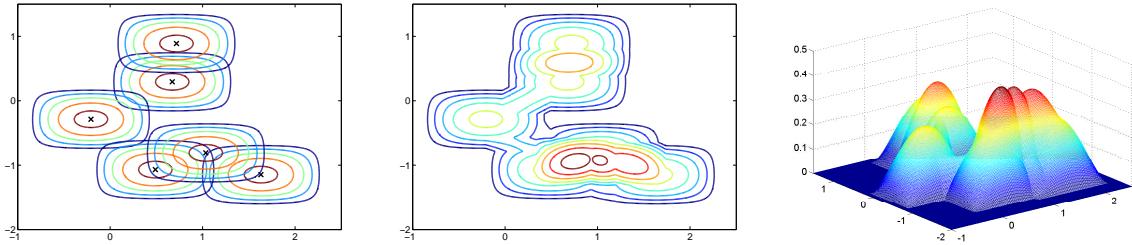
Budeme se zabývat jádrovými odhady s diagonální vyhlazovací maticí. Jádrový odhad s maticí třídy \mathcal{S} dává ve všech směrech stejnou míru vyhlazení, což neponechává příliš mnoho prostoru pro zachycení variabilty dat. Na druhou stranu při použití matice třídy \mathcal{F} je potřeba odhadnout větší počet parametrů, což znamená vyšší výpočetní náročnost.

Konstrukce jádrového odhadu je analogická konstrukci jednorozměrného odhadu. Tedy v každém bodě $[X_i, Y_i]$ sestrojíme jádro $K_{\mathbf{H}}$ a odhad v bodě $[x, y]$ je průměr n hodnot jader v tomto bodě – viz obrázek 5.4.

3 Statistické vlastnosti jádrových odhadů hustoty

Stejně jako u jádrových odhadů jednorozměrných hustot můžeme kvalitu jádrového odhadu hustoty popsat lokálně pomocí střední kvadratické chyby:

$$\text{MSE } \hat{f}(x, y; \mathbf{H}) = \frac{1}{n} \underbrace{\left((K_{\mathbf{H}}^2 * f)(x, y) - (K_{\mathbf{H}} * f)^2(x, y) \right)}_{\text{var}} + \underbrace{\left((K_{\mathbf{H}} * f)(x, y) - f(x, y) \right)^2}_{\text{bias}},$$



Obrázek 5.4: Konstrukce jádrového odhadu hustoty

nebo globálně pomocí střední integrální kvadratické chyby

$$\text{MISE } \hat{f}(x, y; \mathbf{H}) = \iint \text{MSE } \hat{f}(x, y; \mathbf{H}) dx dy.$$

Poznámka 3.1. Podobně jako v jednorozměrném případě se definuje konvoluce funkcí dvou proměnných. Nechť jsou dány funkce f a g , pro které platí $\iint f^2(x, y) dx dy < \infty$ a $\iint g^2(x, y) dx dy < \infty$. Konvoluci $f * g$ definujeme vztahem

$$(f * g)(x, y) = \iint_{-\infty}^{\infty} f(t, u)g(x - t, y - u) dt du.$$

Optimální vyhlazovací matice minimalizuje MISE. Je zřejmé, že tyto optimální hodnoty vyhlazovacích parametrů není možné z MISE přímo vyjádřit. Stejně jako u odhadu jednorozměrných hustot se budeme zabývat asymptotickou střední integrální kvadratickou chybou AMISE.

Věta 3.1. Předpokládejme, že funkce f , jádro K a matice vyhlazovacích parametrů² $\mathbf{H} = \text{diag}(h_1^2, h_2^2)$ splňují následující předpoklady.

- (i) Nechť $\mathbf{H} = \mathbf{H}_n$ je posloupnost matic takových, že $(n|\mathbf{H}|)^{-1}$ a prvky matice \mathbf{H} konvergují k nule pro $n \rightarrow \infty$.
- (ii) Dále nechť všechny druhé parciální derivace funkce f jsou ohraničené, spojité a integrovatelné se čtvercem.
- (iii) Jádro K splňuje

$$\begin{aligned} \iint xK(x, y) dx dy &= \iint yK(x, y) dx dy = 0 \\ \iint x^2 K(x, y) dx dy &= \iint y^2 K(x, y) dx dy = \beta_2(K). \end{aligned}$$

Pak platí

$$\text{MISE}(\mathbf{H}) = \text{AMISE}(\mathbf{H}) + o(h_1^2 + h_2^2) + o((h_1 h_2 n)^{-1}),$$

kde

$$\text{AMISE}(\mathbf{H}) \equiv \text{AMISE } \hat{f}(\cdot, \mathbf{H}) = \frac{V(K)}{nh_1 h_2} + \frac{1}{4} \beta_2^2(K) (h_1^4 V(f_{xx}) + 2h_1^2 h_2^2 V(f_x f_y) + h_2^4 V(f_{yy})), \quad (5.2)$$

přičemž označení je ve shodě s předchozími kapitolami, tj. $V(g) = \iint g^2(x, y) dx dy$.

²Užíváme zde zkráceného zápisu: $\text{diag}(h_1, h_2) = \begin{pmatrix} h_1^2 & 0 \\ 0 & h_2^2 \end{pmatrix}$

Důkaz věty o tvaru AMISE je založen na Taylorově rozvoji funkce $f(x, y)$ a lze jej nalézt např. v knize [14].

Hodnoty parametrů h_1, h_2 , pro které AMISE(h_1, h_2) nabývá minimální hodnoty, jsou dány vztahy:

$$h_{1,opt} = \left(\frac{V^{3/4}(f_{yy})V(K)}{n\beta_2^2(K)V^{3/4}(f_{xx})[V(f_x f_y) + \sqrt{V(f_{xx})V(f_{yy})}]} \right)^{1/6}, \quad (5.3)$$

$$h_{2,opt} = \left(\frac{V^{3/4}(f_{xx})V(K)}{n\beta_2^2(K)V^{3/4}(f_{yy})[V(f_x f_y) + \sqrt{V(f_{xx})V(f_{yy})}]} \right)^{1/6}. \quad (5.4)$$

Z těchto vztahů plyne, že množina přípustných vyhlazovacích parametrů je tvaru $a_1 n^{-1/6} \leq h_1 \leq b_1 n^{-1/6}$, $a_2 n^{-1/6} \leq h_2 \leq b_2 n^{-1/6}$ pro vhodné konstanty $0 < a_1 < b_1 < \infty$, $0 < a_2 < b_2 < \infty$.

4 Volba jádra

Podobně jako u odhadu jednorozměrné hustoty není volba jádra podstatná. Je vhodné zvolit součinový tvar optimálního jádra. Tím zajistíme jistou hladkosť výsledného odhadu a navíc výpočty s využitím součinových jader jsou jednodušší.

Poznámka 4.1. V literatuře se také využívá Gaussovo jádro $K(x, y) = (2\pi)^{-1} e^{-(x^2+y^2)/2}$, které se zdá být výhodnějším při studiu asymptotických vlastností jádrového odhadu. Na druhou stranu má nevýhodu, že jeho nosičem je celá reálná osa, což způsobuje „nedokonalost“ při odhadech hustot s omezeným definičním oborem.

5 Volba vyhlazovacího parametru

5.1 Metoda referenční hustoty

Předpokládejme, že náhodný výběr $([X_1, Y_1], \dots, [X_n, Y_n])$ pochází z normálního rozdělení s hustotou

$$f(x, y) = \frac{1}{2\pi\sigma_1\sigma_2} e^{-\frac{x^2}{2\sigma_1^2} - \frac{y^2}{2\sigma_2^2}}$$

a jádro K je dvourozměrnou standardizovanou normální hustotou, tj.

$$K(x, y) = \frac{1}{2\pi} e^{-\frac{x^2}{2} - \frac{y^2}{2}}.$$

Pak podle metody referenční hustoty lze získat tyto odhady vyhlazovacích parametrů

$$h_{i,\text{REF}} = \hat{\sigma}_i n^{-1/6}, \quad i = 1, 2.$$

Tento vztah je také znám jako Scottovo pravidlo ([11]).

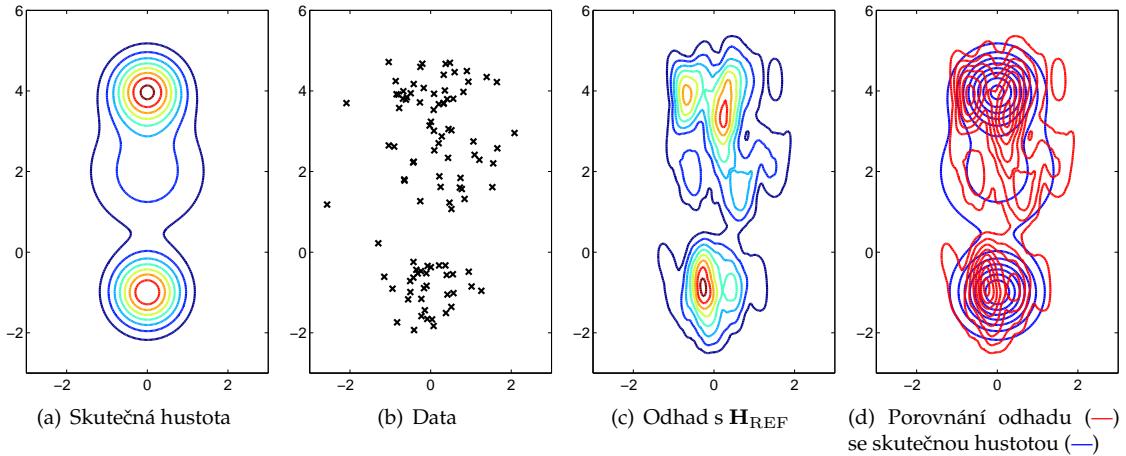
Příklad 5.1. Pro simulovaná data z příkladu 2.1 vychází matice vyhlazovacích parametrů podle metody referenční hustoty s využitím součinového Epanečníkova jádra takto:

$$\mathbf{H}_{\text{REF}} = \begin{pmatrix} 0,3595 & 0 \\ 0 & 0,9972 \end{pmatrix}.$$

Na obrázku 5.5 je vykreslen odhad hustoty s touto maticí a porovnání odhadu se skutečnou hustotou.

Poznámka 5.1. V toolboxu, který doplňuje tato skripta, se uvádí druhá mocnina matice vyhlazovacích parametrů, tedy \mathbf{H}^2 .

Z obrázku 5.5 je patrné, že jádrový odhad je podhlazený, zejména ve směru osy x . Je to způsobeno odhadem směrodatné odchylky, která je základem metody referenční hustoty.



Obrázek 5.5: Jádrový odhad dvourozměrné hustoty – referenční hustota

5.2 Metoda křížového ověřování

Metoda křížového ověřování je založena na odhadu hustoty v bodě $[X_i, Y_i]$ s vynescháním tohoto pozorování. Funkci metody křížového ověřování CV můžeme zapsat ve tvaru

$$\text{CV}(\mathbf{H}) = \iint (\hat{f}(x, y, \mathbf{H}))^2 dx dy - \frac{2}{n} \sum_{i=1}^n \hat{f}_{-i}(X_i, Y_i, \mathbf{H}).$$

kde

$$\hat{f}_{-i}(X_i, Y_i, \mathbf{H}) = \frac{1}{n-1} \sum_{\substack{j=1 \\ j \neq i}}^n K_{\mathbf{H}}(X_i - X_j, Y_i - Y_j)$$

Někdy se metoda CV nazývá nevychýlená metoda křížového ověřování (*unbiased cross-validation*), důvodem je jednoduchý vztah mezi CV a MISE, který uvádí následující věta.

Věta 5.1. *Funkce CV je nevychýleným odhadem MISE, tj. platí*

$$E \text{CV}(\mathbf{H}) = \text{MISE}(\mathbf{H}) - \iint f^2(x, y) dx dy.$$

Důkaz. Vypočtěme střední hodnotu CV:

$$\begin{aligned} E \text{CV}(\mathbf{H}) &= E \iint \hat{f}^2(x, y, \mathbf{H}) dx dy - \frac{2}{n} \sum_{i=1}^n E \hat{f}_{-i}(X_i, Y_i, \mathbf{H}) \\ &= E \iint \hat{f}^2(x, y, \mathbf{H}) dx dy - 2 E K_{\mathbf{H}}(X_1 - X_2, Y_1 - Y_2) \\ &= E \iint \hat{f}^2(x, y, \mathbf{H}) dx dy - 2 \iiint \int K_{\mathbf{H}}(x - u, y - v) f(x, y) f(u, v) dx dy du dv \end{aligned}$$

a úpravou MISE

$$\begin{aligned}
 \text{MISE}(\mathbf{H}) &= E \iint (\hat{f}(x, y, \mathbf{H}) - f(x, y))^2 dx dy \\
 &= E \iint \hat{f}^2(x, y, \mathbf{H}) dx dy - 2E \int \hat{f}(x, y, \mathbf{H}) f(x, y) dx dy + \iint f^2(x, y) dx dy \\
 &= E \iint \hat{f}^2(x, y, \mathbf{H}) dx dy - 2 \iiint K_{\mathbf{H}}(x - u, y - v) f(x, y) f(u, v) dx dy du dv \\
 &\quad + \iint f^2(x, y) dx dy.
 \end{aligned}$$

Porovnáním upravených výrazů dostaneme tvrzení. \square

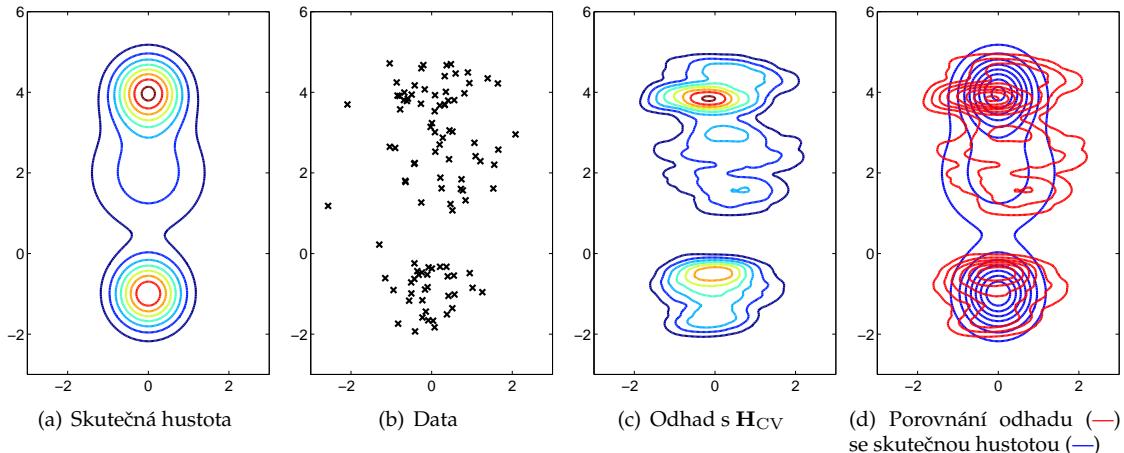
Optimální matici vyhlazovacích parametrů vzhledem k metodě CV označíme \mathbf{H}_{CV} , tj.

$$\mathbf{H}_{\text{CV}} = \arg \min_{\mathbf{H} \in \mathcal{D}} \text{CV}(\mathbf{H}).$$

Příklad 5.2. Použijeme-li součinové Epanečníkovo jádro, pak pro simulovaná data z příkladu 2.1 dostanem matici vyhlazovacích parametrů určenou podle metody křížového ověřování v následujícím tvaru:

$$\mathbf{H}_{\text{CV}} = \begin{pmatrix} 1,2055 & 0 \\ 0 & 0,3783 \end{pmatrix}.$$

Na obrázku 5.6 je vykreslen odhad hustoty s touto maticí.

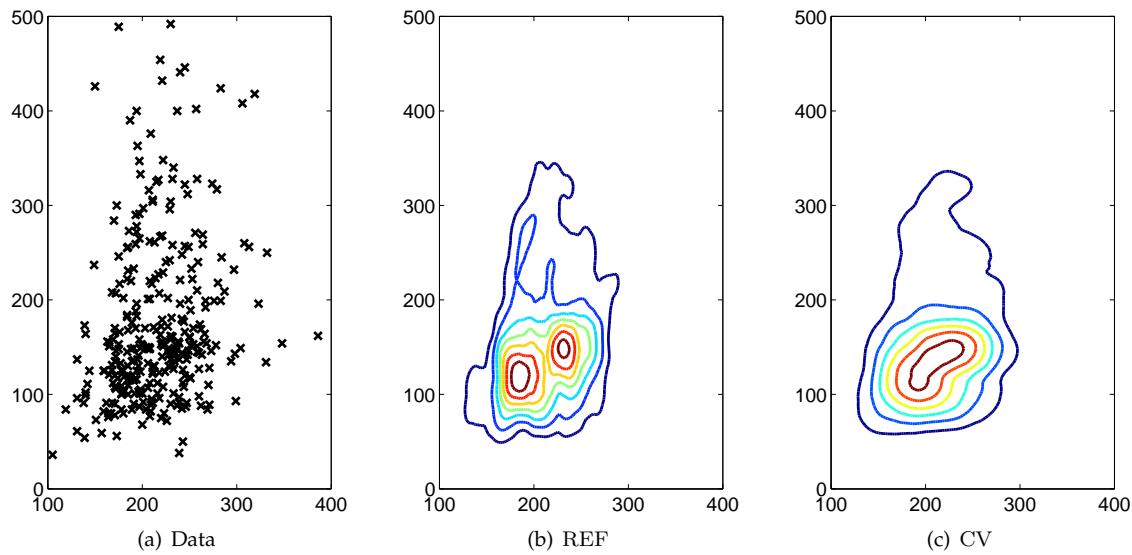


Obrázek 5.6: Jádrový odhad dvourozměrné hustoty – metoda křížového ověřování

Odhad hustoty na obrázku 5.6 se jeví podhlazený, zejména ve směru osy y . Metoda křížového ověřování nedává dobré výsledky pro odhad hustoty vícerozměrných dat, částečně je to způsobeno problémy při minimalizaci funkce křížového ověřování.

6 Aplikace na reálná data

Tento datový soubor pochází ze studie koncentrace lipidů v krevní plazmě, která vyšla v časopise Circulation v roce 1980. Výběrový soubor, který jsme převzali z [11] a s nímž zde pracujeme, obsahuje měření množství cholesterolu a triglyceridu v krevní plazmě u 320 pacientů, kteří si stěžovali na bolest v hrudníku. Data jsou shrnuta v tabulkách 6.9 a 6.10.



Obrázek 5.7: Vrstevnicové grafy odhadnutých hustot pro koncentraci lipidů – na ose x je vynešeno množství cholesterolu (v miligramech na 100 ml plazmy) a na ose y množství triglyceridu v krevní plazmě (mg/100 ml)

Matice vyhlazovacích parametrů určené podle metody referenční hustoty a metody křížového ověřování jsou následující:

$$\mathbf{H}_{\text{REF}} = \begin{pmatrix} 16,45 & 0 \\ 0 & 38,94 \end{pmatrix} \quad \mathbf{H}_{\text{CV}} = \begin{pmatrix} 42,39 & 0 \\ 0 & 29,88 \end{pmatrix}$$

Na obrázku 5.7 jsou znázorněna data a vrstevnice jádrového odhadu s Epanečníkovým součinovým jádrem.

Shrnutí

Odhad dvouozměrné hustoty pravděpodobnosti $f(x, y)$ v bodě $[x, y]$ je tvaru

$$\hat{f}(x, y; \mathbf{H}) = \frac{1}{n|\mathbf{H}|} \sum_{i=1}^n K\left(\mathbf{H}^{-1}(x - X_i, y - Y_i)^T\right)$$

Dva typy jader:

- součinové jádro: $K^P(x, y) = K_1(x) \cdot K_1(y)$,
- sféricky symetrické jádro: $K^S(x, y) = c_k^{-1} K_1(\sqrt{x^2 + y^2})$, $c_k = \iint K_1(\sqrt{x^2 + y^2}) dx dy$.

Asymptotická střední integrální kvadratická chyba dvouozměrného jádrového odhadu

$$\text{AMISE}(\mathbf{H}) = \frac{V(K)}{nh_1 h_2} + \frac{1}{4} \beta_2^2(K) (h_1^4 V(f_{xx}) + 2h_1^2 h_2^2 V(f_x f_y) + h_2^2 V(f_{yy})).$$

Optimální vyhlazovací parametry vzhledem k AMISE

$$h_{1,opt} = \left(\frac{V^{3/4}(f_{yy})V(K)}{n\beta_2^2(K)V^{3/4}(f_{xx})[V(f_x f_y) + \sqrt{V(f_{xx})V(f_{yy})}]} \right)^{1/6},$$

$$h_{2,opt} = \left(\frac{V^{3/4}(f_{xx})V(K)}{n\beta_2^2(K)V^{3/4}(f_{yy})[V(f_x f_y) + \sqrt{V(f_{xx})V(f_{yy})}]} \right)^{1/6}.$$

Metody pro odhad optimálních hodnot matice vyhlazovacích parametrů $\mathbf{H} = \text{diag}(h_1, h_2)$

- metoda referenční hustoty

$$h_{i,\text{REF}} = \widehat{\sigma}_i n^{-1/6}, \quad i = 1, 2,$$

- metoda křížového ověřování

$$\mathbf{H}_{\text{CV}} = \arg \min_{\mathbf{H} \in \mathcal{D}} \text{CV}(\mathbf{H}), \quad \text{CV}(\mathbf{H}) = \iint (\hat{f}(x, y, \mathbf{H}))^2 dx dy - \frac{2}{n} \sum_{i=1}^n \hat{f}_{-i}(X_i, Y_i, \mathbf{H}).$$

Dodatky a cvičení

1. Určete součinové a sféricky symetrické dvouozměrné jádro odvozené z kvartického jádra $K(x) = \frac{15}{16}(1 - x^2)^2$.
2. Odvoďte vztahy (5.3) a (5.4) pro optimální vyhlazovací parametry.
3. Aplikujte metodu referenční hustoty a metodu křížového ověřování na simulovaná i reálná data.