

Kapitola 4

Jádrové odhady distribuční funkce

Výstupy z výukové jednotky

Student

- bude znát základní typy jádrových odhadů distribuční funkce a jejich statistické vlastnosti.
- získá přehled o metodách pro volbu vyhlazovacího parametru.
- bude schopen navrhnut a implementovat proceduru pro zpracování reálných dat.
- se naučí používat příslušný toolbox v Matlabu a dokáže zkonztruovat jádrový odhad distribuční funkce pro daná reálná data.

1 Motivace

Distribuční funkce popisuje rozložení pravděpodobnosti náhodné veličiny (budeme předpokládat spojitost náhodné veličiny). Stejně jako při rekonstrukci hustoty z množiny pozorovaných dat lze distribuční funkci odhadnout parametrickými nebo neparametrickými metodami. Zaměříme se výhradně na neparametrické metody, kdy předpokládáme pouze jistou hladkost odhadované distribuční funkce.

Nejužívanějším neparametrickým odhadem distribuční funkce F je empirická distribuční funkce F_n . Ovšem F_n je schodovitá funkce i v případě, že F je spojitá. Nadaraya (1964) navrhl „hladkou“ alternativu k F , a to jádrový odhad \hat{F} , který se získá integrací známého jádrového odhadu hustoty (3.1)

2 Základní typy neparametrických odhadů

Nechť X_1, \dots, X_n jsou nezávislé náhodné proměnné, které mají tutéž spojitu hustotu f a distribuční funkci F . Nejjednodušší neparametrický dohad distribuční funkce F je *empirická distribuční funkce* \hat{F}_n definovaná v bodě x vztahem

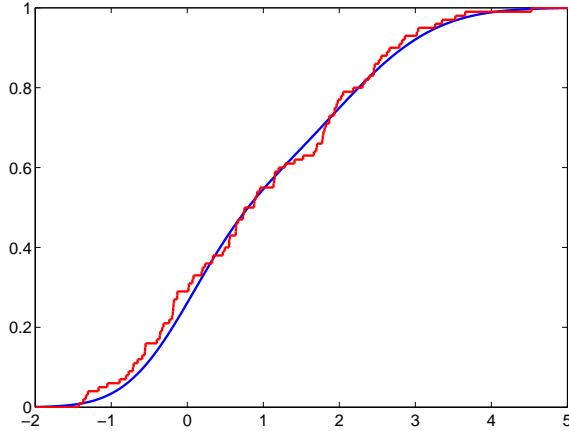
$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(X_i).$$

Tento odhad má sice dobré statistické vlastnosti, ale je to schodovitá funkce (viz obr. 4.1, a proto se budeme zabývat postupy, které umožní zkonztruovat „hladký“ odhad distribuční funkce F .

Příklad 2.1. Mějme dán náhodný výběr o velikosti $n = 100$ ze směsi dvou normálních hustot $N(0; 4/9)$ a $N(2; 1)$ s hustotou

$$f(x) = 0,5 \frac{3}{2\sqrt{2\pi}} e^{-\frac{9x^2}{8}} + 0,5 \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-2)^2}{2}}.$$

(Data jsou v tabulce 6.3.) Z obrázku 4.1 je patrné, že schodovitá funkce nevystihuje plně charakter distribuční funkce.



Obrázek 4.1: Empirická distribuční funkce (červeně) a skutečná distribuční funkce (modře) pro data z příkladu 2.1

Nejznámější postup spočívá v integraci jádrového odhadu hustoty, t.j.

$$\hat{F}(x, h) = \int_{-\infty}^x \hat{f}(t, h) dt = \frac{1}{nh} \sum_{i=1}^n \int_{-\infty}^x K\left(\frac{t - X_i}{h}\right) dt.$$

Užijeme-li substituce $y = (t - X_i)/h$, dostaneme

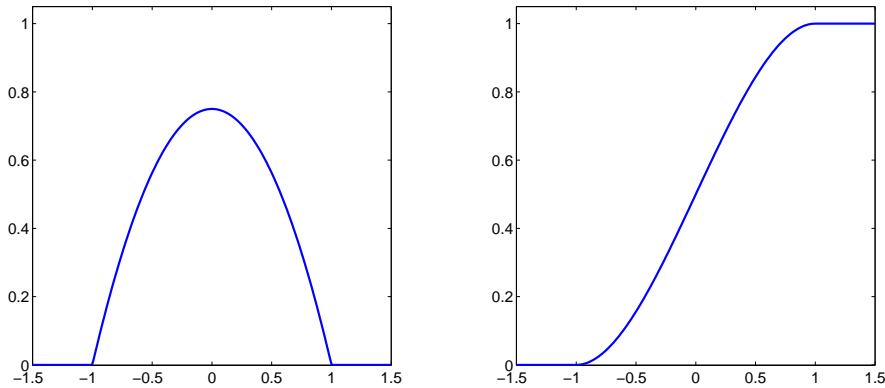
$$\hat{F}(x, h) = \frac{1}{n} \sum_{i=1}^n \int_{-\infty}^{\frac{x-X_i}{h}} K(y) dy = \frac{1}{n} \sum_{i=1}^n W\left(\frac{x - X_i}{h}\right).$$

To znamená, že odhad F v bodě $x \in \mathbb{R}$ je definován takto

$$\hat{F}(x, h) = \frac{1}{n} \sum_{i=1}^n W\left(\frac{x - X_i}{h}\right), \quad W(x) = \int_{-\infty}^x K(t) dt. \quad (4.1)$$

Zde předpokládáme, že $K \in S_{02}$, $K(x) \geq 0$ pro $x \in [-1, 1]$. Níže jsou shrnutý základní vlastnosti funkce W :

1. $W(x) = 0$ pro $x \in (-\infty, -1]$ a $W(x) = 1$ pro $x \in [1, \infty)$,
2. $\int_{-1}^1 W^2(x) dx \leq \int_{-1}^1 W(x) dx = 1$,
3. $\int_{-1}^1 W(x)K(x) dx = \frac{1}{2}$,
4. $\int_{-1}^1 xW(x)K(x) dx = \frac{1}{2} \left(1 - \int_{-1}^1 W^2(x) dx\right)$.

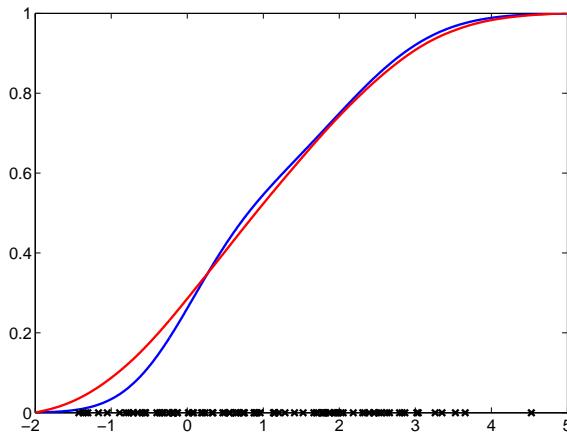


Obrázek 4.2: Epanečníkovo jádro K (vlevo) a k němu příslušná funkce W (vpravo)

Příklad 2.2. Použijeme-li Epanečníkovo jádro $K(x) = \frac{3}{4}(1-x^2)I_{[-1,1]}(x)$, pak funkce W je tvaru

$$W(x) = \begin{cases} 0 & x \leq -1, \\ \frac{1}{4}(-x^3 + 3x + 2) & |x| < 1, \\ 1 & x \geq 1. \end{cases}$$

Pro data z příkladu 2.1 je jádrový odhad distribuční funkce zachycen na obrázku 4.3.



Obrázek 4.3: Jádrový odhad distribuční funkce s parametrem $h = 1,5$

3 Statistické vlastnosti odhadu

Kvalitu jádrového odhadu lze lokálně popsat pomocí střední kvadratické chyby MSE:

$$\begin{aligned} \text{MSE } \widehat{F}(x, h) &= E(\widehat{F}(x, h) - F(x))^2 \\ &= \underbrace{(E\widehat{F}(x, h) - F(x))^2}_{\text{bias}^2} + \underbrace{E(\widehat{F}(x, h))^2 - (E\widehat{F}(x, h))^2}_{\text{var}}. \end{aligned}$$

Spočítejme nejdříve hodnotu $E\widehat{F}(x, h)$ v bodě $x \in \mathbb{R}$:

$$\begin{aligned} E\widehat{F}(x, h) &= \int W\left(\frac{x-y}{h}\right) f(y) dy \\ &= h \int_{-\infty}^1 W(t)f(x-ht) dt + h \int_1^\infty W(t)f(x-ht) dt. \end{aligned}$$

Předpokládejme dále, že $F \in C^2$. Označme první integrál I_1 a druhý I_2 . Integrál I_1 počítáme metodou per partes a využijeme vlastnosti funkce $W(t)$

$$\begin{aligned} I_1 &= h \int_{-\infty}^1 W(t)f(x-ht) dt \\ &= \left| \begin{array}{ll} u = W(t) & u' = W'(t) = K(t) \\ v' = f(x-ht)h & v = -F(x-ht) \end{array} \right| \\ &= [-F(x-ht)]_{-1}^1 + \int_{-1}^1 F(x-ht)W'(t) dt \\ &= -F(x-h) + \int_{-1}^1 K(t)F(x-ht) dt. \end{aligned} \tag{4.2}$$

Dále použijeme Taylorův rozvoj

$$F(x-ht) = F(x) - htF'(x) + \frac{h^2 t^2}{2} F''(x) + o(h^2),$$

tedy

$$I_1 = -F(x-h) + F(x) + \frac{1}{2} F''(x)h^2 \beta_2(K) + o(h^2).$$

Počítejme nyní integrál I_2 :

$$I_2 = h \int_1^\infty W(t)f(x-ht) dt.$$

Uvažujeme-li substituce $x-ht = z$, dostaneme

$$I_2 = - \int_{x-h}^{-\infty} f(z) dz = \int_{-inf}^{x-h} f(z) dz = F(x-h).$$

Vychýlení odhadu je tedy tvaru

$$\text{bias } \widehat{F}(x, h) = \frac{1}{2} F''(x)h^2 \beta_2(K) + o(h^2).$$

Poznámka 3.1. Vztahy (4.2) a (??) dávají zajímavý vztah pro vychýlení

$$E\widehat{F}(x, h) - F(x) = \int_{-1}^1 K(t)F(x-ht) dt - F(x).$$

Odtud plyne

$$E\widehat{F}(x, h) = \int_{-1}^1 K(t)F(x-ht) dt$$

a také (z Taylorova vzorce)

$$E\widehat{F}(x, h) = F(x) + o(h).$$

Nyní dokážeme tvar rozptylu.

$$\text{var } \widehat{F}(x, h) = \frac{1}{n} \left(EW^2 \left(\frac{x - X}{h} \right) - E^2 W \left(\frac{x - X}{h} \right) \right).$$

Zde $E^2 W \left(\frac{x - X}{h} \right) = (EW \left(\frac{x - X}{h} \right))^2 = (F(x) + o(h))^2$. Počítáme tedy pouze integrál I_3 :

$$\begin{aligned} I_3 &= \frac{1}{n} \int_{-\infty}^{\infty} W^2 \left(\frac{x - y}{h} \right) f(y) dy \\ &= |\text{substituce: } x - y = th| \\ &= \frac{1}{n} \left(\int_{-\infty}^1 W^2(t) f(x - ht) dt + h \underbrace{\int_1^{\infty} f(x - ht) dt}_{=F(x-h)} \right). \end{aligned}$$

První integrál počítáme metodou per partes a máme

$$\begin{aligned} I_3 &= \frac{1}{n} [-F(x - ht)W^2(t)]_{-1}^1 + \frac{2}{n} \int F(x - ht)W(t)W'(t) dt + \frac{1}{n} F(x - h) \\ &= -\frac{1}{n} F(x - h) + \frac{2}{n} \int F(x - ht)W(t)K(t) dt + \frac{1}{n} F(x - h) \end{aligned}$$

použijeme nyní Taylorův rozvoj

$$\begin{aligned} &= \frac{2}{n} \int W(t)K(t) (F(x) - htF'(x) + o(h)) dt \\ &= \frac{2}{n} F(x) \int_{-1}^1 W(t)K(t) dt - \frac{2}{n} h F'(x) \int_{-1}^1 t W(t)K(t) dt + o\left(\frac{h}{n}\right) \end{aligned}$$

užitím vlastností funkce W a $F'(x) = f(x)$ dostaneme

$$= \frac{1}{n} \left[F(x) - hf(x) \left(1 - \int_{-1}^1 W^2(t) dt \right) \right] + o\left(\frac{h}{n}\right).$$

Rozptyl je tedy tvaru

$$\begin{aligned} \text{var } \widehat{F}(x, h) &= \frac{1}{n} \left[F(x) - hf(x) \left(1 - \int_{-1}^1 W^2(t) dt \right) \right] + o\left(\frac{h}{n}\right) - (F(x) + o(h))^2 \\ &= \frac{1}{n} F(x)(1 - F(x)) - \frac{h}{n} f(x) \left(1 - \int_{-1}^1 W^2(t) dt \right) + o\left(\frac{h}{n}\right). \end{aligned}$$

Výše uvedené výsledky můžeme nyní zformulovat v následující větě:

Věta 3.1. Nechť $F \in C^2$, $h \rightarrow 0$, $nh \rightarrow \infty$ pro $n \rightarrow \infty$. Pak

$$\text{MSE } \widehat{F}(x, h) = \frac{1}{n} F(x)(1 - F(x)) - \frac{1}{n} hf(x) \left(1 - \int_{-1}^1 W^2(t) dt \right) + \frac{1}{4} (F''(x))^2 h^4 \beta_2^2(K) + o\left(\frac{h}{n} + h^4\right). \quad (4.3)$$

Globální pohled na kvalitu odhadu lze získat prostřednictvím střední integrální kvadratické chyby (MISE).

Věta 3.2. Nechť $F \in C^2$, $V(F'') = \int (F''(x))^2 dx < \infty$, $K \in S_{02}$, $\lim_{n \rightarrow \infty} h = 0$ a $\lim_{n \rightarrow \infty} nh = \infty$. Pak

$$\text{MISE } \widehat{F}(\cdot, h) = \frac{1}{n} \int F(x)(1 - F(x)) dx - c_1 \frac{h}{n} + c_2 h^4 + o\left(\frac{h}{n} + h^4\right), \quad (4.4)$$

kde

$$c_1 = 1 - \int_{-1}^1 W^2(t) dt, \quad c_2 = \frac{1}{4} \beta_2^2(K) V(F'').$$

Naším cílem je nalézt takovou hodnotu vyhlazovacího parametru, pro kterou bude MISE nabývat minimální hodnoty. Ale uvedený tvar MISE není pro takovou analýzu vhodný, a proto (stejně jako při odhadu hustoty a regresní funkce) budeme uvažovat asymptotickou střední integrální kvadratickou chybu AMISE, která v tomto případě je tvaru:

$$\text{AMISE } \widehat{F}(\cdot, h) = \text{AMISE}(h) = \underbrace{\frac{1}{n} \int F(x)(1 - F(x)) dx}_{\text{AIV}} - \underbrace{c_1 \frac{h}{n} + c_2 h^4}_{\text{AISB}}. \quad (4.5)$$

Nyní už lze standardními metodami matematické analýzy nalézt takovou hodnotu h , pro kterou $\text{AMISE}(h)$ nabývá minimální hodnoty. Je snadné ukázat, že

$$h_{opt,0,2} = n^{-1/3} \left(\frac{c_1}{4c_2} \right)^{1/3} = O(n^{-1/3}) \quad (4.6)$$

a pak

$$\text{AMISE}(h_{opt,0,2}) = \frac{1}{n} \int F(x)(1 - F(x)) dx - \frac{3}{c_2^{1/3}} \left(\frac{c_1}{4} \right)^{4/3} n^{-4/3}. \quad (4.7)$$

Poznámka 3.2. Optimální hodnota vyhlazovacího parametru pro odhad distribuční funkce je řádu $n^{-1/3}$, zatímco pro odhad hustoty s jádrem $K \in S_{02}$ je vyhlazovací parametr řádu $n^{-1/5}$.

4 Volba jádra

I v tomto případě je volba jádra méně důležitá než volba vyhlazovacího parametru. Lze doporučit jádra třídy S_{02} , např.

- Epanečníkovo $K(x) = \frac{3}{4}(1 - x^2)I_{[-1,1]}(x)$,
- kvartické $K(x) = \frac{15}{16}(1 - x^2)^2 I_{[-1,1]}(x)$,
- triweight $K(x) = \frac{35}{32}(1 - x^2)^3 I_{[-1,1]}(x)$.

5 Volba vyhlazovacího parametru

5.1 Metody křížového ověřování

Metody křížového ověřování patří k nejužívanějším metodám pro volbu vyhlazovacího parametru.

Zde uvedeme pouze metodu navrženou A. Bowmanem (1998). Funkce křížového ověřování je v tomto případě tvaru

$$\text{CV}(h) = \frac{1}{n} \sum_{i=1}^n \int \left(I_{(-\infty, x]}(X_i) - \widehat{F}_{-i}(x, h) \right)^2 dx,$$

kde $\widehat{F}_{-i}(x, h)$ je jádrový odhad distribuční funkce s vynecháním bodu X_i . Pak

$$h_{\text{CV}} = \arg \min_{h \in H_n} \text{CV}(h),$$

přičemž $H_n = [an^{-1/3}, bn^{-1/3}]$ pro vhodná $0 < a < b < \infty$.

5.2 Princip maximálního vyhlazení

Myšlenka této metody je stejná jako pro odhad hustoty. Užijeme-li faktu, že

$$\int (F''(x))^2 dx = \int (f'(x))^2 dx,$$

můžeme aplikovat Terrellovu větu 5.1 pro $k = 1$. V tomto případě je

$$g_1(x) = \frac{15}{16}(1 - x^2)^2 I_{[-1,1]}(x),$$

a tedy

$$h_{opt,0,2} = n^{-1/3} \left(\frac{c_1}{\beta_2^2(K)V(f')} \right)^{1/3} \leq n^{-1/3} \left(\frac{c_1}{\beta_2^2(K)} \right)^{1/3} \frac{\sigma}{\sigma_1} V(g'_1)^{-1/3},$$

kde $\sigma_1 = \int x^2 g_1(x) dx = \frac{1}{7}$, $V(g'_1) = \frac{15}{7}$. Odtud plynne, že

$$h_{MS} = n^{-1/3} \left(\frac{7c_1}{15\beta_2^2(K)} \right)^{1/3} \sqrt{7}\hat{\sigma}, \quad (4.8)$$

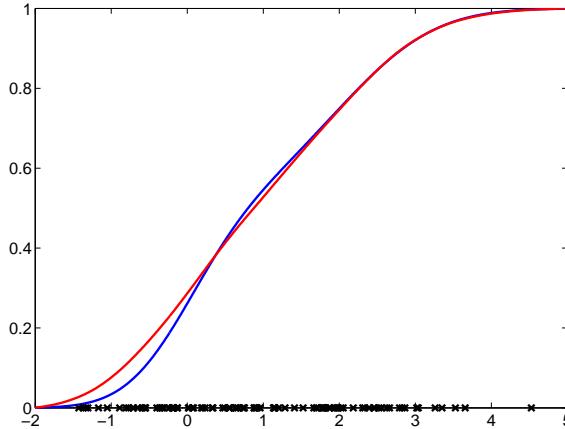
$\hat{\sigma}$ je odhadem σ (viz rovnice (3.11) a (3.12)).

Hodnota h_{MS} může sloužit jako horní hranice pro množinu vyhlazovacích parametrů volených podle metody křížového ověřování. Tedy $H_n = [h_\ell, h_{MS}]$, kde h_ℓ je nejmenší vzdálenost mezi po sobě jdoucími body X_i , $i = 1, \dots, n$.

Příklad 5.1. Pro data z příkladu 2.1 zvolme Epanečníkovo jádro. Pak hodnoty potřebné pro odhad vyhlazovacího parametru metodou maximálního vyhlazení jsou následující:

$$n = 100, \quad \hat{\sigma} = 1,3426, \quad \beta_2(K) = \frac{1}{5}, \quad c_1 = 1 - \int_{-1}^1 W^2(x) dx = 0,2571.$$

Pak platí $h_{MS} = 1,1037$ a na obrázku 4.4 je zobrazen odhad distribuční funkce.



Obrázek 4.4: Odhad distribuční funkce s $h_{MS} = 1,1037$, odhad (—), původní funkce (—)

5.3 Plug-in metoda

Společným cílem metod typu plug-in (PI) je odhadnout $V(F'')$. Za předpokladu dostatečné hladkosti funkce f užitím metody per partes dostaneme vztah

$$V(F'') = \int (F''(x))^2 dx = - \int f''(x)f(x) dx.$$

Tudíž se budeme dále zabývat odhadem funkcionálu

$$\psi_1 = \int f''(x)f(x) dx.$$

Je zřejmé, že $\psi_1 = Ef''(X)$, což vede k metodě založené na odhadu druhé derivace hustoty f . Vztah (3.7) použijeme k odhadu druhé derivace s jádrem $K^{(2)} = K_{opt,2,4} \in S_{24}$. Pak

$$\widehat{\psi}_1 = n^{-1} \sum_{i=1}^n \widehat{f}''(X_i, h) = n^{-2} h^{-3} \sum_{i=1}^n \sum_{j=1}^n K^{(2)} \left(\frac{X_i - X_j}{h} \right),$$

kde podle vztahu (3.9) je

$$h_{opt,2,4} = 10^{1/9} \frac{\delta_{24}}{\delta_{04}} h_{opt,0,4}.$$

Pak

$$\widehat{c}_2 = -\frac{1}{4} \beta_2^2(K) \widehat{\psi}_1.$$

Shrnutím předchozích úvah dostaneme proceduru pro odhad distribuční funkce F :

Krok 1 Najděte optimální vyhlazovací parametr $\widehat{h}_{opt,0,4}$ pro odhad hustoty s optimálním jádrem $K_{opt,0,4} \in S_{04}$.

Krok 2 Najděte optimální vyhlazovací parametr $\widehat{h}_{opt,2,4}$ pro odhad druhé derivace hustoty podle vztahu (3.9) s $k = 4$ a optimálním jádrem $K^{(2)} \in S_{24}$.

Krok 3 Vypočtěte odhad funkcionálu $\widehat{\psi}_1$ s využitím hodnoty $\widehat{h}_{opt,2,4}$ získané v kroku 2.

Krok 4 Vyčíslete optimální hodnotu vyhlazovacího parametru

$$h_{PI} = n^{-1/3} \left(\frac{c_1}{-\widehat{\psi}_1 \beta_2^2(K)} \right)^{1/3}$$

Krok 5 Použijte parametry z předchozích kroků ke konstrukci optimálního jádrového odhadu distribuční funkce $\widehat{F}(x, h)$ s daným jádrem $K \in S_{02}$.

Příklad 5.2. S použitím funkce toolboxu zjistíme, že pro data z příkladu 2.1 je vyhlazovací parametr určený plug-in metodou roven $h_{PI} = 0,5717$. Na obrázku 4.5 je odhad distribuční funkce společně se skutečnou distribuční funkcí.

6 Aplikace na reálná data

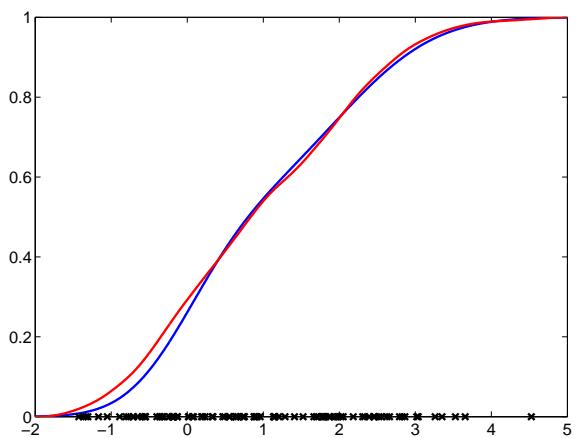
Datový soubor pochází z rozsáhlé studie, v níž autoři studovali vliv substituentů v 2,4-diamino-5-(substituovaný benzyl)pyrimidinech. Biologická aktivita při inhibici dihydrofolát reduktázy byla měřena pomocí asociační konstanty. Data jsou v tabulce 6.8 a jsou dostupná na osobních stránkách Dennise D. Boose¹, kde je také odkaz na původní článek Jonathana D. Hirsta z roku 1994.

Užitím výše uvedených metod jsme (při použití Epanečníkova jádra) dostali následující hodnoty vyhlazovacích parametrů:

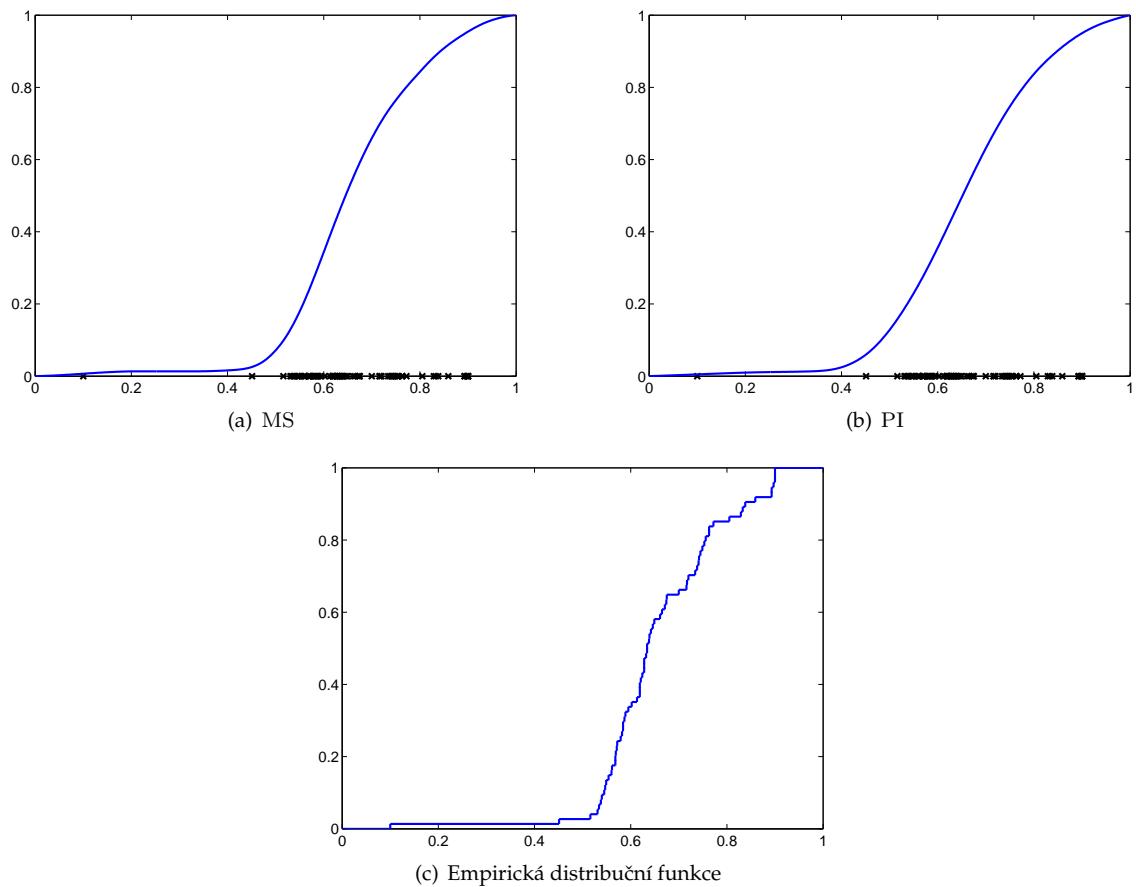
$$h_{MS} = 0,1139, \quad h_{PI} = 0,1931.$$

Na obrázku 4.6 jsou uvedeny odhady distribuční funkce s těmito parametry a také je zde pro srovnání uvedena empirická distribuční funkce.

¹ <http://www4.stat.ncsu.edu/~boos/var.select/pyrimidine.html>



Obrázek 4.5: Odhad distribuční funkce s $h_{\text{PI}} = 0,5717$, odhad (—), původní funkce (—)



Obrázek 4.6: Odhadnuté distribuční funkce

Shrnutí

Odhad distribuční funkce $F(x)$ v bodě x je tvaru

$$\widehat{F}(x) = \frac{1}{n} \sum_{i=1}^n W\left(\frac{x - X_i}{h}\right), \quad W(x) = \int_{-\infty}^x K(t) dt.$$

Asymptotická střední kvadratická chyba jádrového odhadu distribuční funkce je součtem asymptotického tvaru rozptylu (AIV) a druhé mocniny vychýlení (AISB)

$$AMISE(h) = \underbrace{\frac{1}{n} \int F(x)(1 - F(x)) dx}_{AIV} - c_1 \underbrace{\frac{h}{n}}_{AISB} + c_2 h^4,$$

kde

$$c_1 = 1 - \int_{-1}^1 W^2(t) dt, \quad c_2 = \frac{1}{4} \beta_2^2(K) V(F'').$$

Optimální vyhlazovací parametr vzhledem k AMISE pro odhad distribuční funkce je tvaru

$$h_{opt,0,2} = n^{-1/3} \left(\frac{c_1}{4c_2} \right)^{1/3},$$

t.j. $h_{opt,0,2} = O(n^{-1/3})$.

Metody pro odhad optimální hodnoty vyhlazovacího parametru h

- metoda křížového ověřování $h_{CV} = \arg \min_{h \in H_n} CV(h)$

$$CV(h) = \frac{1}{n} \sum_{i=1}^n \int \left(I_{(-\infty, x]}(X_i) - \widehat{F}_{-i}(x, h) \right)^2 dx,$$

- metoda maximálního vyhlazení

$$h_{MS} = n^{-1/3} \left(\frac{7c_1}{15\beta_2^2(K)} \right)^{1/3} \sqrt{7} \widehat{\sigma},$$

- plug-in metoda

$$h_{PI} = n^{-1/3} \left(\frac{c_1}{-\widehat{\psi}_1 \beta_2^2(K)} \right)^{1/3}.$$

Dodatky a cvičení

1. Odvodte tvar funkce $W(x)$ pro kvartické jádro $K(x) = \frac{15}{16}(1-x^2)^2 I_{[-1,1]}(x)$.
2. Dokažte vlastnosti 2, 3 a 4 funkce W .
3. Dokažte vztahy (4.6) a (4.7).
4. Odvodte tvar vyhlazovacího parametru podle metody maximálního vyhlazení pro Epanečníkovo jádro.

5. Odvoďte tvar vyhlazovacího parametru podle plug-in metody pro Epanečníkovo a pro kvartické jádro.
6. Aplikujte metodu maximálního vyhlazení a plug-in metodu na simulovaná i reálná data.