

Selecção multietápica da janela para o estimador do núcleo da função de distribuição

Ana Paula Martins

Universidade da Beira Interior, Departamento de Matemática

Carlos Tenreiro⁽¹⁾

Universidade de Coimbra, Departamento de Matemática

Resumo: Neste artigo propomos versões multietápicas do método *plug-in* para a escolha da janela do estimador do núcleo da função de distribuição introduzido por Altman e Léger [*J. Statist. Plann. Inference* 46, 1995, 195–214]. Um estudo de simulação é desenvolvido para comparar os seguintes estimadores *plug-in*: o estimador de Altman e Léger, os estimadores a zero e a duas etapas, e o estimador das distribuições de referência. O estimador *plug-in* bietápico revela-se o melhor dos estimadores considerados.

Palavras-chave: Função de distribuição; Estimador do núcleo; Selecção da janela.

Abstract: In this paper we propose multistage versions of the plug-in bandwidth selector introduced by Altman and Léger [*J. Statist. Plann. Inference* 46, 1995, 195–214] for kernel distribution function estimators. A simulation study is undertaken to compare the following plug-in kernel estimators: the Altman and Léger estimator, the zero and two stages estimators, and the Normal reference rule estimator. The two stages estimator has a better performance in comparison with the others.

Keywords: Distribution function; Kernel estimator; Plug-in bandwidth selection.

MSC2000: 62G05.

1 Introdução

Sendo X_1, \dots, X_n variáveis aleatórias reais, independentes e absolutamente contínuas com densidade comum f , o estimador do núcleo da função de distribuição F introduzido por Tiago de Oliveira [22], Nadaraya [13] e Watson e Leadbetter [24], é definido, para $x \in \mathbb{R}$, por

$$\widehat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \bar{K}\left(\frac{x - X_i}{h_n}\right),$$

onde, para $u \in \mathbb{R}$,

$$\bar{K}(u) = \int_{]-\infty, u]} K(v)dv.$$

⁽¹⁾Parcialmente financiado por CMUC/FCT.

com K uma função integrável tal que $\int_{\mathbb{R}} K(u)du = 1$ (núcleo), e (h_n) uma sucessão de números reais estritamente positivos convergindo para zero quando $n \rightarrow +\infty$.

A qualidade global da estimação produzida por \widehat{F}_n é habitualmente medida pelo erro quadrático integrado ponderado

$$ISE(h_n, \omega) = \int_{\mathbb{R}} \{\widehat{F}_n(x) - F(x)\}^2 \omega(x)dx, \quad (1)$$

ou pelo erro quadrático médio integrado ponderado

$$MISE(h_n, \omega) = E \left(\int_{\mathbb{R}} \{\widehat{F}_n(x) - F(x)\}^2 \omega(x)dx \right), \quad (2)$$

onde ω é uma função de peso. O comportamento assintótico destas duas medidas foi estudado por Swanepoel [19], Jones [9] e Shirahata e Chu [17]. Para um núcleo fixo, a janela h_n é habitualmente escolhida em função das observações X_1, \dots, X_n . Tal procedimento conduz a uma classe mais vasta de estimadores de F , ditos estimadores automáticos do núcleo, onde $h_n = \widehat{h}_n(X_1, \dots, X_n)$ é uma sucessão de funções mensuráveis. Neste contexto, o comportamento assintótico de (1) foi estudado por Tenreiro [20]. A selecção da janela pelo método da validação cruzada é efectuada por Sarda [16] para funções de peso de suporte compacto e por Bowman *et al.* [3] no caso $\omega = 1$. A metodologia *plug-in* é introduzida por Altman e Léger [1] no caso $\omega = f$, e Polansky e Baker [14] implementam um estimador *plug-in* multietápico no caso $\omega = 1$.

Neste artigo introduzimos versões multietápicas do estimador *plug-in* de Altman e Léger [1]. A dificuldade adicional deste caso relativamente ao caso $\omega = 1$, já considerado por Polansky e Baker [14], reside no facto da janela óptima depender dum parâmetro adicional para o qual é necessário introduzir estimadores multietápicos. Com efeito, se F possui derivada de segunda ordem contínua e limitada, e K é um núcleo com $\int y^2|K(y)|dy < +\infty$, $\int yK(y)dy = 0$, $\int y^2K(y)dy \neq 0$ e $\int yK(y)\bar{K}(y)dy > 0$, sabemos que (cf. Swanepoel [19])

$$h_{MISE}(F) = \operatorname{argmin}_{h>0} MISE(h, f) = h_{AMISE}(1 + o(1)),$$

onde

$$h_{AMISE} = \left(C_K \left(\int F^{(1)}(x)dF(x) / \int F^{(2)}(x)^2 dF(x) \right)^{1/3} n^{-1/3} \right)^2, \quad (3)$$

com

$$C_K = 2 \int yK(y)\bar{K}(y)dy / \left(\int y^2K(y)dy \right)^2.$$

Com o objectivo de definir estimadores multietápicos para os parâmetros $\int F^{(1)}(x)dF(x)$ e $\int F^{(2)}(x)^2 dF(x)$, interessamo-nos no §2 pela estimação dos parâmetros

$$\theta_r = \int F^{(r)}(x)dF(x),$$

para $r = 1, 3, 5, \dots$, e de

$$\theta_{r,r+s} = \int F^{(r)}(x)F^{(r+s)}(x)dF(x),$$

para $r = 1, 2, \dots$ e $s = 0, 1, 2, \dots$. A estimação de θ_r foi considerada por Hall e Marron [7, 8], Bickel e Ritov [2] e Jones e Sheather [10], enquanto a de $\theta_{r,r+s}$ foi considerada por Altman e Léger [1] para $r = 2$ e $s = 0$. O resultado que apresentamos sobre a estimação de θ_r é no essencial devido a Jones e Sheather [10]. No entanto, tal resultado é obtido aqui para uma classe mais vasta de estimadores cujos núcleos gozam de certas propriedades de optimalidade na estimação das derivadas duma densidade de probabilidade (cf. Gasser *et al.* [5] e Granovsky *et al.* [6]). O resultado que obtemos sobre a estimação de $\theta_{r,r+s}$ é o principal resultado deste artigo, generalizando e corrigindo o obtido por Altman e Léger [1].

No §3 propomos um estudo de simulação envolvendo o estimador *plug-in* de Altman e Léger, dois estimadores *plug-in* a zero e a duas etapas, e o estimador das distribuições de referência. O estimador *plug-in* bietápico revela-se o melhor dos quatro estimadores.

As demonstrações dos resultados enunciados são remetidas para o §4.

2 Estimação multietápica de θ_r e $\theta_{r,r+s}$

Para $r \in \{0, 1, 2, \dots\}$ e $\ell \in \{2, 4, 6, \dots\}$ denotaremos por $\mathcal{D}_b(r)$ o conjunto das funções de distribuição com derivadas limitadas até à ordem r , e por $\mathcal{K}_r(\ell)$ o conjunto dos núcleos K limitados de ordem $(r, r + \ell)$, satisfazendo $\int |y|^{r+\ell+1}|K(y)| dy < +\infty$. Assim,

$$\mu_j(K) := \int y^j K(y) dy = \begin{cases} (-1)^r r! \delta_{j,r}, & \text{se } j = 0, 1, \dots, r + \ell - 1 \\ \beta_{r+\ell} \neq 0, & \text{se } j = r + \ell, \end{cases}$$

onde $\delta_{j,r}$ é o delta de Kronecker (cf. Gasser *et al.* [5]). Descrevemos a seguir uma forma simples de construir núcleos em $\mathcal{K}_r(\ell)$. Consideraremos uma função real de variável real K_0 com $\int |y|^{2r+2\ell-1}|K_0(y)| dy < +\infty$ e $\sup_{y \in \mathbb{R}} |y|^{r+\ell-2}|K_0(y)| < +\infty$, e definamos as matrizes N_r e $M_r(u)$ de tipo $(r + \ell - 1) \times (r + \ell - 1)$, onde N_r tem elemento genérico (i, j) dado por $\mu_{i+j-2}(K_0)$, e $M_r(u)$ é definida como N_r mas com a coluna $r + 1$ substituída por $(1, u, \dots, u^{r+\ell-2})^T$. Então

$$K_{r,r+\ell}(u) = (-1)^r r! \left\{ \det(M_r(u)) / \det(N_r) \right\} K_0(u), \quad (4)$$

é um núcleo em $\mathcal{K}_r(\ell)$ (cf. Lejeune e Sarda [11] e Ruppert e Wand [15]).

2.1 Estimação de θ_r

Para $r = 1, 3, 5, \dots$, denotemos por $\widehat{\theta}_r$ o estimador definido por (cf. Hall e Marron [7, 8] e Jones e Sheather [10])

$$\widehat{\theta}_r = \frac{C_{r,\ell}}{nh_n^r} + \frac{1}{n^2 h_n^r} \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n U\left(\frac{X_i - X_j}{h_n}\right), \quad (5)$$

onde $U \in \mathcal{K}_{r-1}(\ell)$, para $\ell \in \{2, 4, 6, \dots\}$ fixo, e $C_{r,\ell}$ é uma constante real não-nula que fixaremos mais tarde.

No resultado seguinte apresentamos um desenvolvimento assintótico para o viés de $\widehat{\theta}_r$ e determinamos a ordem de convergência da sua variância. A sua demonstração é remetida para o §4.

Teorema 1. *Sejam $U \in \mathcal{K}_{r-1}(\ell)$ e $F \in \mathcal{D}_b(r + \ell + 1)$. Então:*

- a) $E(\widehat{\theta}_r) - \theta_r = \frac{C_{r,\ell}}{nh_n^r} + h_n^\ell \frac{\mu_{r+\ell-1}(U)}{(r + \ell - 1)!} \theta_{r+\ell} + O\left(\frac{1}{n} + h_n^{\ell+1}\right);$
- b) $\text{Var}(\widehat{\theta}_r) = O\left(\frac{1}{n} + \frac{2}{n^2 h_n^{2r-1}}\right).$

Admitiremos no que se segue que $h_n \rightarrow 0$ e $nh_n^r \rightarrow +\infty$, o que implica a convergência em média quadrática de $\widehat{\theta}_r$ para θ_r , quando $n \rightarrow +\infty$. A janela óptima, h_r^{opt} , no sentido da minimização assintótica do erro quadrático médio $MSE(\widehat{\theta}_r) = \text{Var}(\widehat{\theta}_r) + (E(\widehat{\theta}_r) - \theta_r)^2$, depende do sinal de $C_{r,\ell} \mu_{r+\ell-1}(U) \theta_{r+\ell}$.

Corolário 1. *Nas condições anteriores, admitimos que $\theta_{r+\ell} \neq 0$.*

- a) Se $C_{r,\ell} \mu_{r+\ell-1}(U) \theta_{r+\ell} < 0$, então

$$h_r^{opt} = \left(\frac{-C_{r,\ell}(r + \ell - 1)!}{\mu_{r+\ell-1}(U) \theta_{r+\ell}} \right)^{1/(r+\ell)} n^{-1/(r+\ell)},$$

e

$$MSE(\widehat{\theta}_r) = O\left(n^{-1} + n^{-(2\ell+1)/(r+\ell)}\right).$$

- b) Se $C_{r,\ell} \mu_{r+\ell-1}(U) \theta_{r+\ell} > 0$, então

$$h_r^{opt} = \left(\frac{C_{r,\ell} r(r + \ell - 1)!}{\ell \mu_{r+\ell-1}(U) \theta_{r+\ell}} \right)^{1/(r+\ell)} n^{-1/(r+\ell)},$$

e

$$MSE(\widehat{\theta}_r) = O\left(n^{-1} + n^{-2\ell/(r+\ell)}\right).$$

Atendendo ao resultado anterior, e uma vez que, sob condições gerais sobre F , $\theta_{4k-1} < 0$ e $\theta_{4k-3} > 0$, para todo o $k \in \mathbb{N}$, vamos, no que se segue, tomar $C_{r,\ell}$ tal que $C_{r,\ell} \mu_{r+\ell-1}(U) > 0$, se $r + \ell = 4k - 1$, para algum $k \in \mathbb{N}$, e $C_{r,\ell} \mu_{r+\ell-1}(U) < 0$, se $r + \ell = 4k - 3$, para algum $k \in \mathbb{N}$.

Para $\ell \in \{2, 4, 6, \dots\}$, fixo, os resultados anteriores permitem-nos apresentar o seguinte esquema de estimação de θ_r a k -etapas, com $k \in \mathbb{N}_0$ (ver Wand e Jones [23], pg. 67–70, para um estimador análogo com $k = \ell = 2$, e Tenreiro [21], sobre o comportamento assintótico dum estimador a k -etapas análogo ao que aqui consideramos):

Etapa 0: Estimar $\theta_{r+k\ell}$ a partir de $\widehat{\theta}_{r+k\ell}$ com janela $h_{r+k\ell}^{opt}$ onde no cálculo de $\theta_{r+(k+1)\ell}$ a distribuição desconhecida F é substituída pela distribuição de referência $F_{N(0,\sigma^2)}$, isto é, $\theta_{r+(k+1)\ell}$ é substituído por

$$R_{r+(k+1)\ell}(\widehat{\sigma}) = \int F_{N(0,\widehat{\sigma}^2)}^{(r+(k+1)\ell)}(x) dF_{N(0,\widehat{\sigma}^2)}(x),$$

com $F_{N(0,\sigma^2)}$ a função de distribuição da distribuição normal de média 0 e variância σ^2 , e $\widehat{\sigma}$ é um estimador da escala da distribuição desconhecida F .

Etapa b ($1 \leq b \leq k$): Estimar $\theta_{r+(k-b)\ell}$ usando $\widehat{\theta}_{r+(k-b)\ell}$ com janela $h_{r+(k-b)\ell}^{opt}$, onde $\theta_{r+(k-b+1)\ell}$ é substituído por $\widehat{\theta}_{r+(k-b+1)\ell}$.

2.2 Estimação de $\theta_{r,r+s}$

Para $r = 1, 2, \dots$ e $s = 0, 1, 2, \dots$, consideramos o estimador $\widehat{\theta}_{r,r+s}$ definido por (cf. Altman e Léger [1], para $r = 2$ e $s = 0$)

$$\widehat{\theta}_{r,r+s} = \frac{1}{n(n-1)^2 h_n^{2r+s}} \sum_{i=1}^n \sum_{\substack{j \neq i \\ k \neq i}} V\left(\frac{X_i - X_j}{h_n}\right) W\left(\frac{X_i - X_k}{h_n}\right), \quad (6)$$

onde $V \in \mathcal{K}_{r-1}(\ell)$ e $W \in \mathcal{K}_{r+s-1}(\ell)$, para $\ell \in \{2, 4, 6, \dots\}$ fixo.

O viés assintótico e a ordem de convergência da variância de $\widehat{\theta}_{r,r+s}$ são dados no resultado seguinte cuja demonstração é apresentada no §4.

Teorema 2. Sejam $V \in \mathcal{K}_{r-1}(\ell)$, $W \in \mathcal{K}_{r+s-1}(\ell)$ e $F \in \mathcal{D}_b(r+s+\ell+1)$. Então:

a) $E(\widehat{\theta}_{r,r+s}) - \theta_{r,r+s}$

$$= h_n^\ell \kappa_{r,r+s}(V, W) + \frac{\mu_0(VW)}{nh_n^{2r+s-1}} \theta_1 + O\left(\frac{1}{nh_n^{2r+s-2}} + h_n^{\ell+1}\right),$$

onde

$$\kappa_{r,r+s}(V, W) = \frac{(-1)^{r-1} \mu_{r+\ell-1}(V)}{(r+\ell-1)!} \theta_{r+\ell,r+s} + \frac{(-1)^{r+s-1} \mu_{r+s+\ell-1}(W)}{(r+s+\ell-1)!} \theta_{r,r+s+\ell};$$

b) $\text{Var}(\widehat{\theta}_{r,r+s}) = O\left(\frac{1}{n} + \frac{1}{n^2 h_n^{4r+2s-3}} + \frac{1}{n^3 h_n^{4r+2s-2}} + \frac{1}{n^4 h_n^{4r+2s-1}}\right).$

Decorre do resultado anterior que a convergência em média quadrática de $\widehat{\theta}_{r,r+s}$ para $\theta_{r,r+s}$, quando $n \rightarrow +\infty$, ocorre sempre que $h_n \rightarrow 0$ e $nh_n^{2r+s-1} \rightarrow$

$+\infty$, o que assumiremos. A janela óptima, $h_{r,r+s}^{opt}$, no sentido da minimização assintótica do erro quadrático médio $MSE(\hat{\theta}_{r,r+s})$, depende agora não só de $\mu_0(VW)$ ser ou não zero, mas também do sinal de $\kappa_{r,r+s}(V,W) \mu_0(VW)$. No resultado seguinte analisamos apenas o caso $\mu_0(UV) \neq 0$.

Corolário 2. Nas condições anteriores, admitimos que $\kappa_{r,r+s}(V,W) \neq 0$.

a) Se $\kappa_{r,r+s}(V,W) \mu_0(VW) < 0$, então

$$h_{r,r+s}^{opt} = \left(\frac{-\mu_0(VW) \theta_1}{\kappa_{r,r+s}(V,W)} \right)^{1/(2r+s+\ell-1)} n^{-1/(2r+s+\ell-1)},$$

e

$$MSE(\hat{\theta}_{r,r+s}) = O\left(n^{-(2\ell+1)/(2r+s+\ell-1)}\right).$$

b) Se $\kappa_{r,r+s}(V,W) \mu_0(VW) > 0$, então

$$h_{r,r+s}^{opt} = \left(\frac{(2r+s-1)\mu_0(VW) \theta_1}{\ell \kappa_{r,r+s}(V,W)} \right)^{1/(2r+s+\ell-1)} n^{-1/(2r+s+\ell-1)},$$

e

$$MSE(\hat{\theta}_{r,r+s}) = O\left(n^{-2\ell/(2r+s+\ell-1)}\right).$$

De forma análoga ao que fizemos atrás, e admitindo que possuímos já um estimador de θ_1 , os resultados anteriores permitem-nos apresentar o seguinte esquema de estimação de $\theta_{r,r+s}$ a k -etapas, com $k \in \mathbb{N}_0$, onde $\ell \in \{2, 4, 6, \dots\}$ está fixo à partida:

Etapa 0: Estimar $\theta_{r+i,r+s+j}$, para $i,j = 0,\ell,2\ell,\dots,k\ell$ e $i+j = k\ell$, utilizando $\hat{\theta}_{r+i,r+s+j}$ com janela $h_{r+i,r+s+j}^{opt}$ onde $\theta_{r+i,r+s+j}$ é substituído por

$$R_{r+i,r+s+j}(\hat{\sigma}) = \int F_{N(0,\hat{\sigma}^2)}^{(r+i)}(x) F_{N(0,\hat{\sigma}^2)}^{(r+s+j)}(x) dF_{N(0,\hat{\sigma}^2)}(x).$$

Etapa b ($1 \leq b \leq k$): Estimar $\theta_{r+i,r+s+j}$, para $i,j = 0,\ell,2\ell,\dots,(k-b)\ell$ e $i+j = (k-b)\ell$, a partir de $\hat{\theta}_{r+i,r+s+j}$ com janela $h_{r+i,r+s+j}^{opt}$ definida com $\hat{\theta}_{r+i+\ell,r+s+j}$ e $\hat{\theta}_{r+i,r+s+j+\ell}$ no lugar de $\theta_{r+i+\ell,r+s+j}$ e $\theta_{r+i,r+s+j+\ell}$, respectivamente.

3 Estudo de simulação

Propomos neste parágrafo um estudo de simulação envolvendo quatro estimadores do núcleo da função de distribuição que descreveremos a seguir, e um conjunto de distribuições de probabilidade constituído por 15 misturas de normais definidas no §3 de Marron e Wand [12]. Os gráficos das suas densidades e funções de distribuição são apresentados na Figura 1.

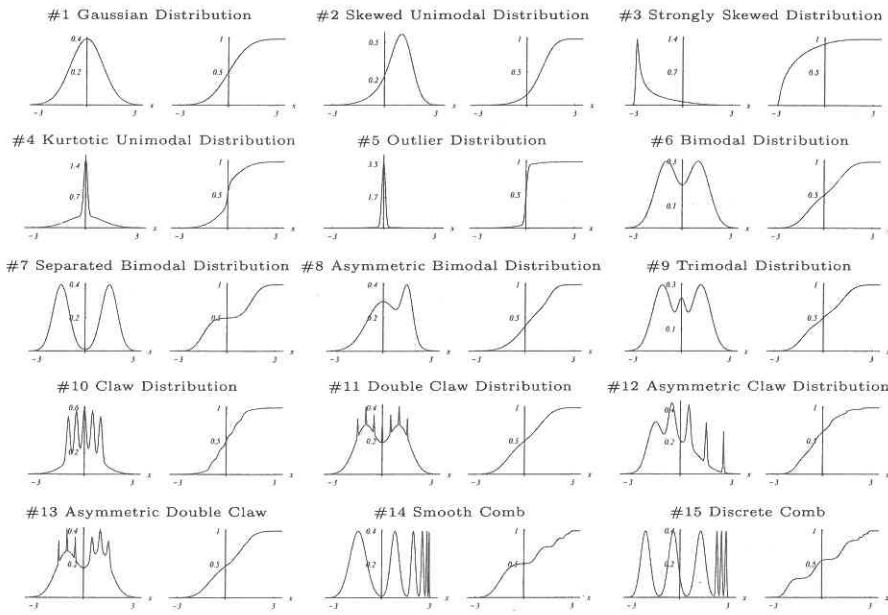


Figura 1: Mistura de normais consideradas no estudo de simulação

Dos resultados de Swanepoel [19] e Jones [9], sabemos que o núcleo uniforme é óptimo no sentido da minimização do erro quadrático médio integrado (2). No entanto, como nesse caso as estimativas produzidas por \widehat{F}_n não são contínuas, não reflectindo a propriedade respectiva de F , tomaremos para K o núcleo normal standard $K(x) = \exp(-x^2/2)/\sqrt{2\pi}$. Relativamente à escolha da janela, e tendo em conta (3) tomaremos

$$\widehat{h}_n = (C_K \widehat{\theta}_1 / \widehat{\theta}_{2,2})^{1/3} n^{-1/3},$$

onde $C_K = 1/\sqrt{\pi}$, e $\widehat{\theta}_1$ e $\widehat{\theta}_{2,2}$ estimadores de θ_1 e $\theta_{2,2}$, respectivamente.

Em cada um dos estimadores $\widehat{\theta}_r$ e $\widehat{\theta}_{r,r+s}$ que consideramos, tomamos $\ell = 2$ e núcleos da forma (4) com $K_0 = K$. Assim $\widehat{\theta}_r$ será definido por (5) com $U = K_{r-1,r+\ell-1}$ e $C_{r,\ell} = K_{r-1,r+\ell-1}(0)$, e $\widehat{\theta}_{r,r+s}$ será definido por (6) com $V = K_{r-1,r+\ell-1}$ e $W = K_{s-1,s+\ell-1}$. Quando optamos por um esquema de estimação multietápica, a etapa 0 de estimação descrita no §2 depende da fixação dum estimador da escala da distribuição desconhecida F . Seguindo a sugestão de Silverman [18], pg. 47, consideramos $\widehat{\sigma} = \min(\widehat{S}, \widehat{R}/1.349)$, onde \widehat{S} é o desvio-padrão empírico e \widehat{R} a amplitude interquartil empírica.

Estimador plug-in de Altman e Léger (AL): Em Altman e Léger [1], $\widehat{\theta}_1$ e $\widehat{\theta}_{2,2}$ são definidos com janelas deterministas iguais a $n^{-0.3}$. Tomaremos aqui

tais janelas iguais a $\hat{\sigma} n^{-1/3}$ e $\hat{\sigma} n^{-1/5}$, respectivamente, que, como vimos, são as ordens de convergência para zero das janelas óptimas, e $\hat{\sigma}$ é introduzido para correcção do efeito de escala.

Estimador plug-in a zero etapas (PI-0): Neste estimador $\hat{\theta}_1$ e $\hat{\theta}_{2,2}$ são estimadores a zero etapas de θ_1 e $\theta_{2,2}$, respectivamente.

Estimador plug-in a duas etapas (PI-2): Os estimadores $\hat{\theta}_1$ e $\hat{\theta}_{2,2}$ são aqui estimadores a duas etapas de θ_1 e $\theta_{2,2}$, respectivamente. Na implementação deste último estimador, substituímos θ_1 pelo seu estimador a duas etapas.

Estimador das distribuições de referência (DRN): O método das distribuições de referência foi introduzido por Deheuvels [4] no contexto da estimação da densidade de probabilidade e consiste na substituição da distribuição desconhecida F que surge na expressão (3) de h_{AMISE} , por uma distribuição de referência que consideramos normal $N(0, \hat{\sigma}^2)$, onde $\hat{\sigma}$ é um estimador da escala da distribuição.

| Distr. / n | AL | PI-0 | PI-2 | DRN | Distr. / n | AL | PI-0 | PI-2 | DRN |
|--------------|--------|--------|--------|--------|--------------|--------|--------|--------|--------|
| #1 20 | 93.84 | 89.47 | 91.56 | 92.64 | #2 20 | 94.63 | 86.87 | 92.59 | 94.07 |
| 50 | 96.21 | 93.35 | 94.64 | 96.03 | 50 | 94.90 | 85.06 | 94.74 | 95.68 |
| 100 | 97.33 | 94.34 | 96.75 | 97.88 | 100 | 96.76 | 90.22 | 96.47 | 97.20 |
| 200 | 98.42 | 97.31 | 98.02 | 98.79 | 200 | 97.77 | 94.06 | 97.49 | 98.13 |
| 500 | 98.77 | 97.72 | 98.64 | 99.21 | 500 | 98.55 | 95.59 | 98.71 | 98.52 |
| #3 20 | 88.69 | 67.84 | 94.51 | 91.05 | #4 20 | 92.40 | 79.94 | 95.50 | 94.39 |
| 50 | 77.60 | 50.07 | 89.02 | 74.62 | 50 | 81.71 | 64.06 | 89.66 | 82.57 |
| 100 | 67.55 | 36.54 | 85.83 | 57.84 | 100 | 81.63 | 59.42 | 93.18 | 78.79 |
| 200 | 72.00 | 34.04 | 93.41 | 53.00 | 200 | 84.98 | 96.59 | 95.81 | 97.76 |
| 500 | 74.15 | 32.83 | 95.82 | 44.86 | 500 | 90.46 | 53.60 | 98.80 | 71.21 |
| #5 20 | 93.22 | 80.30 | 93.04 | 92.51 | #6 20 | 99.79 | 99.59 | 96.49 | 98.17 |
| 50 | 95.47 | 82.56 | 95.99 | 95.26 | 50 | 101.03 | 98.37 | 98.54 | 101.62 |
| 100 | 96.64 | 89.18 | 96.67 | 96.75 | 100 | 99.84 | 92.63 | 99.14 | 100.30 |
| 200 | 97.40 | 93.18 | 97.40 | 97.43 | 200 | 100.34 | 96.46 | 99.42 | 100.60 |
| 500 | 98.40 | 96.04 | 98.44 | 98.30 | 500 | 99.49 | 93.99 | 99.52 | 99.54 |
| #7 20 | 91.63 | 77.01 | 100.48 | 93.73 | #8 20 | 101.36 | 98.21 | 98.02 | 100.69 |
| 50 | 89.12 | 54.73 | 100.17 | 83.46 | 50 | 102.97 | 97.59 | 101.53 | 102.85 |
| 100 | 88.71 | 35.27 | 99.57 | 72.34 | 100 | 100.86 | 95.99 | 100.03 | 101.68 |
| 200 | 93.99 | 29.40 | 99.70 | 71.02 | 200 | 99.92 | 95.28 | 99.75 | 100.42 |
| 500 | 96.96 | 34.82 | 99.69 | 70.37 | 500 | 99.64 | 95.62 | 99.52 | 99.81 |
| #9 20 | 106.16 | 104.54 | 101.58 | 104.78 | #10 20 | 120.70 | 117.01 | 117.57 | 118.86 |
| 50 | 103.62 | 99.44 | 101.55 | 103.91 | 50 | 113.38 | 107.05 | 111.81 | 114.04 |
| 100 | 101.56 | 93.28 | 101.22 | 101.81 | 100 | 107.48 | 103.65 | 107.08 | 107.63 |
| 200 | 100.37 | 92.06 | 100.25 | 100.57 | 200 | 103.04 | 101.08 | 102.83 | 103.13 |
| 500 | 99.70 | 94.02 | 99.86 | 99.59 | 500 | 90.17 | 87.44 | 91.33 | 91.08 |
| #11 20 | 129.71 | 126.92 | 124.28 | 128.15 | #12 20 | 119.96 | 114.32 | 117.03 | 118.15 |
| 50 | 119.29 | 115.62 | 117.01 | 119.23 | 50 | 110.69 | 103.38 | 109.67 | 111.03 |
| 100 | 112.79 | 109.18 | 111.49 | 112.88 | 100 | 108.04 | 103.17 | 107.34 | 108.89 |
| 200 | 109.44 | 104.61 | 108.78 | 109.81 | 200 | 101.67 | 97.96 | 101.94 | 102.98 |
| 500 | 105.62 | 100.81 | 105.55 | 105.68 | 500 | 95.47 | 90.21 | 98.64 | 96.33 |
| #13 20 | 125.74 | 122.17 | 122.07 | 124.48 | #14 20 | 113.09 | 105.87 | 113.40 | 114.02 |
| 50 | 116.63 | 110.93 | 114.73 | 116.97 | 50 | 95.07 | 75.77 | 103.09 | 95.49 |
| 100 | 111.55 | 102.40 | 110.86 | 112.15 | 100 | 85.18 | 53.98 | 100.65 | 80.36 |
| 200 | 107.13 | 99.88 | 106.72 | 107.62 | 200 | 87.09 | 46.79 | 100.79 | 75.26 |
| 500 | 103.37 | 96.45 | 103.63 | 103.19 | 500 | 88.15 | 40.38 | 99.95 | 66.70 |
| #15 20 | 119.25 | 118.13 | 114.58 | 116.44 | | | | | |
| 50 | 96.88 | 92.87 | 96.48 | 97.79 | | | | | |
| 100 | 76.48 | 71.50 | 82.68 | 79.85 | | | | | |
| 200 | 65.15 | 53.92 | 90.72 | 67.12 | | | | | |
| 500 | 69.84 | 36.00 | 99.24 | 56.04 | | | | | |

Tabela 1. Eficiência (eff)

Os estimadores anteriores são comparados através da medida de eficiência,

$$\text{eff} = \sqrt{\frac{\text{E}(ISE(h_{AMISE}))^2}{\text{E}(ISE(\hat{h}_n))^2}} \times 100\%$$

onde h_{AMISE} é dado por (3). Esta medida de eficiência reflecte não só a média (MISE) mas também a variabilidade associada ao erro quadrático integrado $ISE(\hat{h}_n)$.

Para cada um dos quatro estimadores do núcleo descritos, para cada uma das distribuições de probabilidade consideradas, e para vários valores de n , apresentamos na Tabela 1 estimativas da medida de eficiência anterior baseadas em amostras de tamanho 500. Os resultados obtidos revelam que o estimador PI-2 é o melhor dos estimadores considerados. Os estimadores AL, PI-0 e DRN apesar de revelarem eficiência elevada para a maioria das distribuições consideradas, possuem baixa eficiência para as distribuições #3, #4, #7, #14 e #15.

4 Demonstrações

Demonstração do Teorema 1: a) Consequência da igualdade

$$\text{EU}\left(\frac{X_i - X_j}{h_n}\right) = h_n \int \int U(z)f(x - zh_n)dz dF(x),$$

onde, para $U \in \mathcal{K}_{r-1}(\ell)$ e $F \in \mathcal{D}_b(r + \ell + 1)$,

$$\begin{aligned} & \int U(z)f(x - zh_n)dz \\ &= \frac{(-1)^{r-1}}{(r-1)!} h_n^{r-1} \int U(z)z^{r-1} dz F^{(r)}(x) \\ &+ \frac{(-1)^{r+\ell-1}}{(r+\ell-1)!} h_n^{r+\ell-1} \int U(z)z^{r+\ell-1} dz F^{(r+\ell)}(x) \\ &+ \frac{(-1)^{r+\ell}}{(r+\ell-1)!} h_n^{r+\ell} \int U(z)z^{r+\ell} F^{(r+\ell+1)}(x - tz h_n) dz, \text{ com } t \in]0, 1[. \end{aligned} \tag{7}$$

b) Temos

$$\text{Var}(\hat{\theta}_r) = \frac{1}{n^4 h_n^{2r}} \sum_{\#\{i_1, j_1\} \cap \{i_2, j_2\} \neq 0} K_n(i_1, j_1, i_2, j_2) + \frac{6 - 4n}{n(n-1)} \text{E}^2\left(\hat{\theta}_r - \frac{C_{r,\ell}}{nh_n^r}\right),$$

onde a soma é tomada para todos os índices $i_1, j_1, i_2, j_2 \in \{1, \dots, n\}$, com $j_1 \neq i_1$ e $j_2 \neq i_2$, e

$$K_n(i_1, j_1, i_2, j_2) = \text{EU}\left(\frac{X_{i_1} - X_{j_1}}{h_n}\right) U\left(\frac{X_{i_2} - X_{j_2}}{h_n}\right).$$

Para obter a alínea b) basta agora usar a) e ter em conta que $K_n(i_1, j_1, i_2, j_2) = h_n^{2r} E(F^{(r)}(X_1))^2 + O(h_n^{2r+\ell})$, se $\#\{i_1, j_1\} \cap \{i_2, j_2\} = 1$, e $K_n(i_1, j_1, i_2, j_2) = O(h_n)$ se $\#\{i_1, j_1\} \cap \{i_2, j_2\} = 2$. ■

Demonstração do Teorema 2: a) Temos

$$E(\widehat{\theta}_{r,r+s}) = \frac{1}{n(n-1)^2 h_n^{2r+s}} \sum_{i=1}^n \sum_{\substack{j \neq i \\ k \neq i}} K_n(i, j, k),$$

onde

$$K_n(i, j, k) = EV\left(\frac{X_i - X_j}{h_n}\right) W\left(\frac{X_i - X_k}{h_n}\right).$$

Utilizando (7) obtemos, para $F \in \mathcal{D}_b(r+s+\ell+1)$,

$$\begin{aligned} K_n(i, j, k) &= h_n^2 \int \left\{ \int V(z) f(x - zh_n) dz \right\} \left\{ \int W(z) f(x - zh_n) dz \right\} dF(x) \\ &= h_n^{2r+s} \theta_{r,r+s} + h_n^{2r+s+\ell} \kappa_{r,r+s}(V, W) + O(h_n^{2r+s+\ell+1}), \end{aligned}$$

se $j \neq k$. Por outro lado, para $j = k$, obtemos $K_n(i, j, k) = h_n \mu_0(VW) \theta_1 + O(h_n^2)$.

A alínea a) é consequência imediata das igualdades anteriores.

b) Tendo em conta os desenvolvimentos obtidos acima para $K_n(i, j, k)$, podemos escrever

$$\begin{aligned} \text{Var}(\widehat{\theta}_{r,r+s}) &= \frac{1}{n^2(n-1)^4 h_n^{4r+2s}} \sum_{\#\{i_1, j_1, k_1\} \cap \{i_2, j_2, k_2\} \neq 0} K_n(i_1, j_1, k_1, i_2, j_2, k_2) \\ &\quad + O\left(\frac{1}{n} + \frac{1}{n^2 h_n^{2r+s-1}} + \frac{1}{n^3 h_n^{4r+2s-2}}\right), \end{aligned} \quad (8)$$

onde o somatório anterior é tomado para todos os índices $i_1, j_1, k_1, i_2, j_2, k_2 \in \{1, \dots, n\}$, com $j_1 \neq i_1$, $k_1 \neq i_1$, $j_2 \neq i_2$ e $k_2 \neq i_2$, e

$$\begin{aligned} K_n(i_1, j_1, k_1, i_2, j_2, k_2) &= EV\left(\frac{X_{i_1} - X_{j_1}}{h_n}\right) W\left(\frac{X_{i_1} - X_{k_1}}{h_n}\right) V\left(\frac{X_{i_2} - X_{j_2}}{h_n}\right) W\left(\frac{X_{i_2} - X_{k_2}}{h_n}\right). \end{aligned}$$

Estudemos agora o termo $K_n = K_n(i_1, j_1, k_1, i_2, j_2, k_2)$ em cada um dos casos seguintes:

— $\#\{i_1, j_1, k_1\} \cap \{i_2, j_2, k_2\} = 1$: os termos mais significativos ocorrem quando i) $i_1 = i_2, j_1 \neq k_1, j_2 \neq k_2$, ii) $i_1 = i_2, j_1 = k_1, j_2 \neq k_2$ e iii) $i_1 = i_2, j_1 = k_1, j_2 = k_2$, obtendo-se, respectivamente, i) $K_n = O(h_n^{4r+2s})$, ii) $K_n = O(h_n^{2r+s+1})$ e iii) $K_n = O(h_n^2)$. Assim,

$$\frac{1}{n^2(n-1)^4 h_n^{4r+2s}} \sum_{\#\{i_1, j_1, k_1\} \cap \{i_2, j_2, k_2\} = 1} K_n = O\left(\frac{1}{n} + \frac{1}{n^2 h_n^{2r+s-1}} + \frac{1}{n^3 h_n^{4r+2s-2}}\right)$$

— $\#\{i_1, j_1, k_1\} \cap \{i_2, j_2, k_2\} = 2$: os termos mais significativos ocorrem quando i) $i_1 = j_2, j_1 = k_2, j_1 \neq k_1$, ii) $i_1 = k_2, j_1 = j_2$, iii) $i_1 \neq i_2, j_1 = k_1 = j_2 = k_2$ e iv) $i_1 = i_2, j_1 = k_1 = k_2, j_2 \neq k_2$, obtendo-se, respectivamente, i) $K_n = O(h_n^{r+s+2})$, ii) $K_n = O(h_n^3)$, iii) $K_n = O(h_n^2)$ e iv) $K_n = O(h_n^{r+1})$. Assim,

$$\frac{1}{n^2(n-1)^4 h_n^{4r+2s}} \sum_{\#\{i_1, j_1, k_1\} \cap \{i_2, j_2, k_2\} = 2} K_n = O\left(\frac{1}{n^2 h_n^{4r+2s-3}} + \frac{1}{n^3 h_n^{3r+2s-1}}\right).$$

— $\#\{i_1, j_1, k_1\} \cap \{i_2, j_2, k_2\} = 3$: os termos mais significativos ocorrem quando i) $i_1 = i_2, j_1 = j_2 = k_1 = k_2$ e ii) $i_1 = i_2, j_1 = j_2, k_1 = k_2, j_1 \neq k_1$ obtendo-se i) $K_n = O(h_n)$ e ii) $K_n = O(h_n^2)$, respectivamente. Assim,

$$\frac{1}{n^2(n-1)^4 h_n^{4r+2s}} \sum_{\#\{i_1, j_1, k_1\} \cap \{i_2, j_2, k_2\} = 3} K_n = O\left(\frac{1}{n^3 h_n^{4r+2s-2}} + \frac{1}{n^3 h_n^{4r+2s-1}}\right).$$

As igualdades anteriores, conjuntamente com o desenvolvimento (8), permitem obter o resultado desejado. ■

Bibliografia

- [1] Altman, N. e Léger, C. (1995). Bandwidth selection for kernel distribution function estimation. *J. Statist. Plann. Inference*, Vol. 46, p. 195–214.
- [2] Bickel, P. e Ritov, Y. (1988). Estimating integrated squared density derivatives: sharp best order of convergence estimates. *Sankhyā*, Vol. 50, Ser. A, p. 381–393.
- [3] Bowman, A., Hall, P. e Prvan, T. (1998). Bandwidth selection for the smoothing of distribution functions. *Biometrika*, Vol. 85, p. 799–808.
- [4] Deheuvels, P. (1977). Estimation non paramétrique de la densité par histogrammes généralisés. *Revue Statist. Appliquée*, Vol. 28, p. 25–55.
- [5] Gasser, Th., Müller, H.-G. e Mammitzsch, V. (1985). Kernels for nonparametric curve estimation. *Scand. J. Statist.*, Vol. 11, p. 197–211.
- [6] Granovsky, B.L., Müller, H.G. e Pfeifer, C. (1995). Some remarks on optimal kernel functions. *Statist. Decisions*, Vol. 13, p. 101–116.
- [7] Hall, P. e Marron, J.S. (1987). Estimation of integrated squared density derivatives. *Statist. Probab. Letters*, Vol. 6, p. 109–115.
- [8] Hall, P. e Marron, J.S. (1991). Lower bounds for bandwidth selection in density estimation. *Probab. Th. Rel. Fields*, Vol. 90, p. 149–173.
- [9] Jones, M.C. (1990). The performance of kernel density functions in kernel distribution function estimation. *Statist. Probab. Letters*, Vol. 9, p. 129–132.
- [10] Jones, M.C. e Sheather, S.J. (1991). Using non-stochastic terms to advantage in kernel-based estimation of integrated squared density derivatives. *Statist. Probab. Letters*, Vol. 11, p. 511–514.
- [11] Lejeune, M. e Sarda, P. (1992). Smooth estimators of distribution and density functions. *Computat. Statist. Data Anal.*, Vol. 9, p. 129–132.

- [12] Marron, J.S. e Wand, M.P. (1992). Exact mean integrated squared error. *Ann. Statist.*, Vol. 20, p. 712–736.
- [13] Nadaraya, E.A. (1964). Some new estimates for distribution functions. *Theory Probab. Appl.*, Vol. 9, p. 497–500.
- [14] Polansky, A.M. e Baker, E.R. (2000). Multistage plug-in bandwidth selection for kernel distribution function estimates. *J. Statist. Comput. Simul.*, Vol. 65, p. 63–80.
- [15] Ruppert, D. e Wand, M.P. (1992). Multivariate locally weighted least squares regression. *Ann. Statist.*, Vol. 22, p. 1346–1370.
- [16] Sarda, P. (1993). Smoothing parameter selection for smooth distribution functions. *J. Statist. Plann. Inference*, Vol. 35, p. 65–75.
- [17] Shirahata, S. e Chu, I-S. (1992). Integrated squared error of kernel-type estimator of distribution function. *Ann. Inst. Statist. Math.*, Vol. 44, p. 579–591.
- [18] Silverman, J. (1986). *Density Estimation for Statistics and Data Analysis*. Chapman & Hall.
- [19] Swanepoel, J. (1988). Mean integrated squared error properties and optimal kernels when estimating a distribution function. *Commun. Statist. – Theory Meth.*, Vol. 17, p. 3785–3799.
- [20] Tenreiro, C. (2002). On the asymptotic behaviour of the ISE for automatic kernel distribution estimators. *Pré-publicação 02–06, DMUC*.
- [21] Tenreiro, C. (2002). On the asymptotic normality of multistage integrated density derivatives estimators. *Pré-publicação 02–18, DMUC*.
- [22] Tiago de Oliveira, J. (1963). Estatística de densidades, resultados assintóticos. *Rev. Fac. Ciências Lisboa*, Vol. 9, 2^a Sér. A, p. 111–206.
- [23] Wand, M.P. e Jones, M.C. (1995). *Kernel Smoothing*. Chapman & Hall.
- [24] Watson, G.S. e Leadbetter, M.R. (1964). Hazard Analysis II. *Sankhyā*, Vol. 26, Ser. A, p. 101–116.