

مقایسه کوچک نمونه‌ای برآوردهای تابع چگالی با روش‌های هسته‌گاما و سری‌های متعامد

محی‌الدین ایزدی^{*} ، عبدالله جلیلیان
دانشگاه رازی، گروه آمار

دریافت ۹۷/۱۲/۱۱ پذیرش ۹۶/۰۷/۲۲

چکیده

برآوردگر هسته‌ای استاندارد دچار مشکل اربیبی مرزی برای تابع‌های چگالی احتمال توزیع‌هایی با تکیه‌گاه اعداد حقیقی مثبت است. برآوردگرهای هسته‌ای گاما و سری‌های متعامد دو جای‌گزین برای برآوردگر هسته‌ای استاندارد هستند که میرا از اربیبی مرزی‌اند. در این مقاله یک بررسی شبیه‌سازی بهمنظور مقایسه عملکرد کوچک‌نمونه‌ای برآوردگرهای هسته‌ای گاما و برآوردگر سری‌های متعامد با پایه‌های لاغر و ارمیت اجرا شده است. بر اساس این مطالعه شبیه‌سازی دریافتیم که اگر انتخاب پایه برای برآوردگر سری‌های متعامد بر اساس شناخت جزئی از شکل تابع چگالی هدف باشد، برآوردگر سری‌های متعامد می‌تواند عملکردی بهتر از برآوردگر هسته‌ای گاما داشته باشد.

واژه‌های کلیدی: اربیبی مرزی، میانگین جمع‌بسته توان دوم خطأ، پارامتر هموارساز.

کد موضوع‌بندی ریاضی (۲۰۱۰) : 93E14 .62Gxx .62G07

مقدمه

برآورد ناپارامتری تابع چگالی احتمال بر اساس یک نمونه تصادفی از آن یکی از پویاترین زمینه‌های پژوهشی آمار در چند دهه اخیر بوده است. مقاله‌های مورثی و کتاب‌های متعددی در مورد روش‌های موجود و سیر تکوینی آن‌ها بحث کرده‌اند (تاپیا و تامسون [۱]، سیلورمن [۲]، آیزنمن [۳]، واند و جونز [۴] و دوروی و لوگوسی [۵]). فرض کنید X_1, \dots, X_n نمونه‌ای تصادفی از یک توزیع احتمال با تابع چگالی نامعلوم $f: R \rightarrow [0, \infty]$ باشد. یکی از نام‌آشناترین

برآوردگرهای تابع چگالی f در نقطه $x \in R$ ، طبق رابطه (۱) است:

$$(1) \quad \hat{f}(x; \delta) = \frac{1}{n\delta} \sum_{i=1}^n K\left(\frac{x-X_i}{\delta}\right)$$

که در آن K تابع هسته و $\delta > 0$ پارامتر هموارساز یا پهنه‌ای نوار^۱ نامیده می‌شود. تابع هسته اغلب یک تابع چگالی احتمال متقارن $K(-u) = K(u)$ با ویژگی‌های

$$\int_R K(u) du = 1, \quad \int_R u K(u) du = 0, \quad \int_R u^2 K(u) du < \infty,$$

است. هم‌چنین فرض می‌شود که پارامتر هموارساز $\delta = \delta_n$ نیز هنگامی که $n \rightarrow \infty$ در شرط‌های $0 \rightarrow \delta$ و $\infty \rightarrow n\delta$ صدق می‌کند. برآوردگر $\hat{f}(x; \delta)$ ، به برآوردگر هسته‌ای استاندارد و یا برآوردگر پارزن-روزنبلت معروف است. نشان داده شده است که با انتخاب مناسب پارامتر هموارساز، برآوردگر هسته‌ای استاندارد سازگار بوده است و میانگین توان دوم خطای آن و هم‌چنین میانگین جمع‌بسته توان دوم خطأ^۲،

*نویسنده مسئول m.izadi@razi.ac.ir

1. Bandwidth

2. Mean Integrated Squared Error

$$MISE(\hat{f}) = E \int_R [f - \hat{f}(x; \delta)]^2 dx, \quad (2)$$

با نرخ رشد $O(n^{-\frac{4}{5}})$ به صفر همگرا است (پارزن [۶]). سیلورمن [۲] و واند و جونز [۴] مروی جامع بر عملکرد و ویژگی‌های برآورده‌گر هسته‌ای استاندارد تابع چگالی داشته‌اند که خوانندگان علاقه‌مند می‌توانند به این مراجع رجوع کنند.

با وجود این هنگامی که تکیه‌گاه تابع چگالی بازه‌ای کران دار مانند $[a, b]$ باشد، برآورده‌گر (۱) عملکرد مناسبی در نقاط نزدیک به مرزها که ناحیه مرزی گفته می‌شود، ندارد. در واقع این برآورده‌گر در نقاط مرزی دارای اribi است که به مسئله اribi مرزی^۱ معروف است. از آنجاکه در بسیاری از کاربردها، کمیت‌های تصادفی مورد بررسی نامنفی هستند، استفاده از برآورده‌گر هسته‌ای استاندارد مناسب نیست، زیرا این برآورده‌گر در نقاط نزدیک به صفر دارای مسئله اribi مرزی است. به طور مثال، فرض کنید f یک تابع چگالی حتمال با تکیه‌گاه $(0, \infty)$ باشد که مشتق دوم آن موجود و در یک همسایگی $x = 0$ پیوسته است. در این صورت برای تابع هسته متقارن K با تکیه‌گاه $[1, -1]$ و هر $x \in [0, \delta]$ (مارون و راپرت [۷]),

$$\begin{aligned} Bias \{ \hat{f}(x; \delta) \} &= E \hat{f}(x; \delta) - f(x) \\ &= -f(x) \int_{\frac{x}{\delta}}^1 K(u) du - \delta f'(x) \int_{-1}^{\frac{x}{\delta}} u K(u) du \\ &\quad + \frac{\delta^2}{2} f''(x) \int_{-1}^{\frac{x}{\delta}} u^2 K(u) du + o(\delta^2). \end{aligned}$$

بنابراین واضح است که برای $x \in [0, \delta]$ برآورده‌گر هسته‌ای استاندارد دارای اribi است. به عنوان مثال،

$$Bias \hat{f}(0; \delta) \simeq \frac{1}{2} f(0).$$

برای رهایی از این مشکل راه‌کارهای متعددی پیشنهاد شده است که از جمله می‌توان به روش بازتاب داده‌ها (شوستر [۸]، سیلورمن [۲] و کلاین و هارت [۹]، روش هسته‌های کران دار (گسر و همکاران [۱۰]، مولر [۱۱]، [۱۲] و جونز [۱۳]) و روش تبدیل داده‌ها (وند و همکاران [۱۴] و مارون و راپرت [۷]) اشاره کرد. یکی از روش‌های بسیار موثر در این زمینه استفاده از هسته‌های نامتقارن است. چن [۱۵] استفاده از هسته بتا را برای برآورد تابع چگالی با تکیه‌گاه $[0, 1]$ پیشنهاد و بررسی کرده است. چن [۱۶] برای برآورد تابع‌های چگالی با تکیه‌گاه $(0, \infty)$ ، دو برآورده‌گر با هسته گاما معرفی کرده و نشان داده است که این برآورده‌گرها میرا از مسئله اribi مرزی است. همچنین وی با استفاده از بررسی‌های شبیه‌سازی نشان داده است که این برآورده‌گرها دارای عملکرد بهتری نسبت به برآورده‌گرهای معرفی شده به وسیله جونز [۱۳]، جونز و فوستر [۱۷] و مولر و وانگ [۱۸] است. مالک و شاینلی [۱۹] نیز به بررسی مقایسه عملکرد برآورده‌گرهای گاما با برآورده‌گرها ارائه شده شوستر [۸]، کارونامونی و آلبرت [۲۰]، گسر و مولر [۲۱] و جونز و فوستر [۱۷] پرداخته‌اند. آن‌ها با استفاده از شبیه‌سازی، برای حالت‌های مختلفی از تابع چگالی، نشان داده‌اند که در حالت کلی برآورده‌گرهای گاما به ویژه برآورده‌گر نوع اول نسبت به برآورده‌گرهای دیگر دارای عملکرد مناسب‌تر و یا رقابت‌پذیرند.

اما برآورده‌گرهای هسته‌ای تنها برآورده‌گرهای پیشنهاد شده برای برآورد ناپارامتری تابع چگالی نیستند. برآورده‌گرهای سری‌های متعامد^۲ دسته دیگری از برآورده‌گرها هستند که نخستین بار چنکوف [۲۰] معرفی کرد و پس از آن سایر

1. Boundary bias

2. Orthogonal series estimators

پژوهش‌گران بررسی کردند. در این برآوردها، ضرایب هموارسازی در نظر گرفته می‌شوند که همانند پهنهای نوار در روش برآوردهایی بر عملکرد برآوردها تأثیرگذارند و در عمل باید به صورت بهینه انتخاب شوند [۲۳]. بررسی‌های بزرگ نمونه‌ای نشان داده‌اند که برآوردهای سری‌های متعامد نیز مانند برآوردهای هسته‌ای خواص مجانبی مطلوبی دارند [۲۴]. مروری جامع بر این نوع برآوردها را *إفروموج* [۲۵] ارائه کرده است.

در این مقاله، با در نظر گرفتن چندین تابع چگالی خاص، رفتار کوچک نمونه‌ای برآوردهای هسته‌ای مبتنی بر هسته گاما و برآوردهای سری‌های متعامد را بررسی و عملکرد آنها را در قالب یک بررسی شبیه‌سازی با یکدیگر مقایسه می‌کنیم. برای این منظور، برآوردهای هسته‌ای با هسته گاما در بخش بعد و برآوردهای سری‌های متعامد در بخش سوم معرفی می‌شوند. سپس در بخش پایانی عملکرد این برآوردها برای چند تابع چگالی معین بررسی و مقایسه می‌شود.

برآورد با هسته گاما

فرض کنید f یک تابع چگالی احتمال با تکیه‌گاه $(0, \infty)$ و X_1, X_2, \dots, X_n نمونه‌ای تصادفی از f باشد. چنان‌که گفته شد، استفاده از برآوردهای هسته‌ای استاندارد در همسایگی نقطه صفر دارای اربیی است. برای رفع این مشکل [۱۶] دو برآوردهای هسته‌ای که در آن‌ها از تابع چگالی گاما به عنوان تابع هسته استفاده شده است را معرفی کرد. فرض کنید

$$K(u; \alpha, \beta) = \frac{1}{\Gamma(\alpha)\beta^\alpha} u^{\alpha-1} \exp\left(-\frac{u}{\beta}\right), \quad u \geq 0,$$

تابع چگالی توزیع گاما با پارامتر شکل $\alpha > 0$ و پارامتر مقیاس $\beta > 0$ باشد. برآوردهای

$$\hat{f}_{g_1}(x; \omega) = \frac{1}{n} \sum_{i=1}^n K\left(X_i; \frac{x}{\omega} + 1, \omega\right), \quad x \geq 0, \quad (3)$$

نخستین کلاس از برآوردهای گاما است که چن [۱۶] معرفی کرده است. در برابری (۳)، $\omega_n = \omega$ دنباله‌ای از اعداد مثبت است که پارامتر هموارساز نامیده می‌شود و در شرط‌های $0 \rightarrow \omega \rightarrow \infty$ و $n\omega \rightarrow \infty$ هنگامی که $n \rightarrow \infty$ صدق می‌کند. چن نشان داد

$$E[\hat{f}_{g_1}(x; \omega)] = f(x) + \omega \left\{ f'(x) + \frac{x}{2} f''(x) \right\} + o(\omega) \quad (4)$$

و

$$Var[\hat{f}_{g_1}(x; \omega)] \sim \begin{cases} \frac{1}{2\sqrt{\pi}} n^{-1} \omega^{-\frac{1}{2}} x^{-1/2} f(x), & \frac{x}{\omega} \rightarrow \infty \\ \frac{\Gamma(2\kappa+1)}{2^{1+2\kappa}} \Gamma^2(\kappa+1) n^{-1} \omega^{-1} f(x), & \frac{x}{\omega} \rightarrow \kappa, \end{cases}$$

که در آن f' و f'' به ترتیب مشتق‌های اول و دوم f است. چون اربیی برآوردهای $O(\omega)$ است، بنابراین این برآوردهای مبنا از مسئله اربیی مرزی برآوردهای استاندارد است. اما وجود f' در (۴) مطلوب نیست، از این رو چن [۱۶] کلاس دیگری از برآوردهای هسته‌ای گاما را به صورت (۵) معرفی کرد:

$$\hat{f}_{g_2}(x; \omega) = \frac{1}{n} \sum_{i=1}^n K(X_i; \rho_\omega(x), \omega), \quad x \geq 0 \quad (5)$$

که در آن

$$\rho_\omega(x) = \begin{cases} \frac{x}{\omega}, & x \geq 2\omega, \\ \left(\frac{x}{2\omega}\right)^2 + 1, & x \in [0, 2\omega). \end{cases}$$

می‌توان نشان داد

$$Bias\{\hat{f}_{g_2}(x; \omega)\} = \begin{cases} \frac{1}{2}xf''(x)\omega + o(\omega), & x \geq 2\omega \\ \xi_\omega(x)\omega f'(x) + o(\omega), & x \in [0, 2\omega] \end{cases} \quad (6)$$

که در آن

$$\xi_\omega(x) = (1-x) \frac{\rho_\omega(x) - \frac{x}{\omega}}{1 + \omega\rho_\omega(x) - x}.$$

با توجه به برابری (۶)، مشاهده می‌شود که f' تنها به‌ازای x ‌هایی که در بازه کوچکی در نزدیکی صفراند در میزان اریبی برآورده $\hat{f}_{g_2}(\cdot; \omega)$ تأثیرگذار است.

برآورد با سری‌های متعامد

فرض کنید $L^2 = L^2(0, \infty)$ مجموعه همه تابع‌های $R: [0, \infty) \rightarrow R$ باشد به گونه‌ای که

$$\int_0^\infty h^2(x) dx < \infty.$$

در این صورت L^2 یک فضای هیلبرت با ضرب داخلی

$$\langle h, g \rangle = \int_0^\infty h(x)g(x)dx, \quad h, g \in L^2$$

و نرم

$$\|h\| = \sqrt{\langle h, h \rangle} = \left(\int_0^\infty h^2(x) dx \right)^{\frac{1}{2}}, \quad h \in L^2$$

است [۲۶]. اگر گردایه $\{\phi_j: j \in \mathbb{N}_0\} \subset L^2$ باشد، آن‌گاه هر $h \in L^2$ دارای بسط یکتای

$$h(x) = \sum_{i=0}^{\infty} c_j \phi_j(x)$$

برحسب ϕ_j ‌ها است که در آن

$$c_j = \langle h, \phi_j \rangle = \int_0^\infty h(x)\phi_j(x)dx.$$

با فرض این که $f \in L^2$ ، تابع چگالی f بر حسب پایه $\{\phi_j: j \in \mathbb{N}_0\}$ دارای بسط

$$f(x) = \sum_{j=0}^{\infty} \theta_j \phi_j(x)$$

با ضرایب

$$\theta_j = \langle h, \phi_j \rangle = \int_0^\infty f(x)\phi_j(x)dx = E[\phi_j(X)]$$

است. با توجه به این که $\theta_j = E[\phi_j(X)]$

$$\hat{\theta}_j = \frac{1}{n} \sum_{i=1}^n \phi_j(X_i)$$

یک برآورده نااریب و سازگار برای θ_j و در نتیجه

$$\hat{f}_\infty(x) = \sum_{j=0}^{\infty} \hat{\theta}_j \phi_j(x),$$

یک برآوردگر ناریب برای $f(x)$ است (واتسون [۲۷]). با این حال $\hat{f}_{\infty}(x)$ واریانسی نامتناهی دارد و محاسبه آن در عمل امکان‌پذیر نیست (وهبا [۲۳]). برای رفع مشکل نامتناهی بودن واریانس \hat{f}_{∞} می‌توان ضرایب $\hat{\theta}_j$ را با وزن‌های b_j منقبض و از این برآوردگر استفاده کرد [۲۴]:

$$\hat{f}(x; \mathbf{b}) = \sum_{j=0}^{\infty} b_j \hat{\theta}_j \phi_j(x).$$

در برآوردگر $\hat{f}(\cdot; \mathbf{b})$ بردار $\mathbf{b} = (b_0, b_1, b_2, \dots)$ را بردار هموارساز گویند و فرض می‌شود $0 \leq b_j \leq 1$ و $\sum_{j=0}^{\infty} b_j < \infty$. یک انتخاب رایج برای \mathbf{b} :

$$b_j = \begin{cases} 1, & j \leq J \\ 0, & j > J \end{cases} \quad (7)$$

است که منجر به برآوردگر بریده شده^۱ (۸) می‌شود:

$$\hat{f}_o(x; J) = \sum_{j=0}^J \hat{\theta}_j \phi_j(x). \quad (8)$$

وهبا [۲۳] استفاده از ضرایب هموارساز پارامتری

$$b_j = b_j(c_1, c_2) = \frac{1}{\{1 + c_1 j^{c_2}\}}$$

را پیشنهاد کرد که در آن $c_2 > 1$ و $c_1 > 0$ مجھول هستند.

بدیهی است که بردار هموارساز \mathbf{b} بر عملکرد برآوردگر $\hat{f}_o(\cdot; \mathbf{b})$ تأثیرگذار است و باید به روش بهینه‌ای انتخاب شود. در حالت کلی میانگین جمع‌بسته توان دوم خطای (۲) برای $\hat{f}_o(\cdot; \mathbf{b})$ برابر است با:

$$MISE(\hat{f}_o(\cdot; \mathbf{b})) = \sum_{j=0}^{\infty} b_j^2 Var(\hat{\theta}_j) + \sum_{j=0}^{\infty} (b_j - 1)^2 \theta_j^2.$$

اما

$$E[(\hat{\theta}_j)^2] = \frac{1}{n^2} E\left[\left(\sum_{i=1}^n \phi_j(X_i)\right)^2\right] = = \frac{1}{n} E[\phi_j^2(X)] + \theta_j^2 \left(1 - \frac{1}{n}\right)$$

۹

$$Var(\hat{\theta}_j) = E[(\hat{\theta}_j)^2] - [E(\theta_j)]^2 = \frac{1}{n} (E[\phi_j^2(X)] - \theta_j^2).$$

بنابراین

$$MISE(\hat{f}_o(\cdot; \mathbf{b})) = \sum_{j=0}^{\infty} \left[\frac{b_j^2}{n} (E[\phi_j^2(X)] - \theta_j^2) + \theta_j^2 (b_j^2 - 2b_j) \right] + \sum_{j=0}^{\infty} \theta_j^2.$$

با توجه به این که (برابری پارسوال^۲)

$$\sum_{j=0}^{\infty} \theta_j^2 = \int_R f^2(x) dx$$

به بردار هموارساز \mathbf{b} بستگی ندارد، کمینه‌سازی $MISE(\hat{f}_o(\cdot; \mathbf{b}))$ نسبت به \mathbf{b} با کمینه‌سازی

$$I(\mathbf{b}) = MISE(\hat{f}_o(\cdot; \mathbf{b})) - \int_R f(x) d x = \sum_{j=0}^{\infty} \left[\frac{b_j^2}{n} (E[\phi_j^2(X)] - \theta_j^2) + \theta_j^2 (b_j^2 - 2b_j) \right]$$

1. Truncated estimator
2. Parseval's identity

معادل است [۲۸]. بنابراین انتخاب بهینه \mathbf{b} با کمینه‌سازی $I(\mathbf{b})$ تعیین می‌شود. به عنوان مثال، انتخاب بهینه مقدار برینشی^۱ $J = J_n$ در بردار هموارساز (۷) با کمینه‌سازی

$$I(J) = \sum_{j=0}^J \left[\frac{1}{n} (E[\phi_j^2(X)] - \theta_j^2) - \theta_j^2 \right] \quad (9)$$

نسبت به ... $J = 0, 1, 2, \dots$ به دست می‌آید. در عمل مقدار θ_j^2 مجهول است که می‌توان آن را با برآوردگر نالاریب

$$\widehat{\theta_j^2} = \frac{1}{n(n-1)} \sum_{1 \leq i < l \leq n} \phi_j(X_i) \phi_j(X_l)$$

برآورد کرد. همچنین با استفاده از

$$D_j = \frac{1}{n} \sum_{i=1}^n \phi_j^2(X_i)$$

به عنوان برآورد $E[\phi_j^2(X)]$ با کمینه‌سازی

$$\hat{I}(\mathbf{b}) = \sum_{j=0}^{\infty} \left[\frac{b_j^2}{n} (D_j - \widehat{\theta_j^2}) + \widehat{\theta_j^2} (b_j^2 - 2b_j) \right]$$

برآورده برای بردار هموارساز \mathbf{b}_n به دست می‌آید [۲۴].

ویژگی‌های بزرگ نمونه‌ای \mathbf{b}_n و $\hat{f}_0(\cdot; \mathbf{b}_n)$ با در نظر گرفتن برخی شرایط برای تابع چگالی f بررسی شده‌اند

[۲۸]. به عنوان مثال، برای بردار هموارساز (۷)، اگر برای مقدار برینشی $J = J_n$ داشته باشیم $\infty \rightarrow J \rightarrow 0$

هرگاه $\infty \rightarrow n$ و بعلاوه J از مرتبه $O(n^{\frac{1}{q}})$ باشد، آن‌گاه میانگین جمع‌بسته توان دوم خطای $(\hat{f}_0(\cdot; \mathbf{b}))$

با نرخ رشد $O(n^{-(1-\frac{1}{q})})$ به صفر همگرا است [۲۹].

انتخاب پایه یکامتعامد $\{\phi_j : j \in \mathbb{N}_0\}$ به تکیه‌گاه f بستگی دارد. برای تابع‌های چگالی با تکیه‌گاه فشرده مانند

بازه $[0, a]$ اغلب از پایه مثلثاتی

$$\phi_j(x) = \begin{cases} \frac{1}{\sqrt{a}}, & j = 0 \\ \sqrt{\frac{2}{a}} \cos\left(\frac{j\pi x}{a}\right), & j \geq 1 \end{cases}$$

استفاده می‌شود، در حالی که برای تابع‌های چگالی با تکیه‌گاه R ، پایه ارمیت نرمال شده^۲

$$\phi_j(x) = \frac{1}{\sqrt{2^j j! \sqrt{\pi}}} e^{-\frac{x^2}{2}} H_j(x)$$

که در آن

$$H_j(x) = (-1)^j e^{x^2} \left(\frac{d^j}{dx^j} e^{-x^2} \right), \quad j \geq 0,$$

چندجمله‌ای ارمیت مرتبه j -ام است و برای تابع‌های چگالی با تکیه‌گاه $[0, \infty]$ ، پایه لاغر نرمال شده^۳

$$\phi_j(x) = e^{-\frac{x^2}{2}} L_j(x)$$

که در آن

$$L_j(x) = \frac{1}{j!} e^x \left[\frac{d^j}{dx^j} (e^{-x} x^j) \right] = \sum_{k=0}^j \binom{j}{k} \frac{(-1)^k}{k!} x^k, \quad j \geq 0,$$

1. Cutoff value

2. Normalized Hermite basis

3. Normalized Laguerre basis

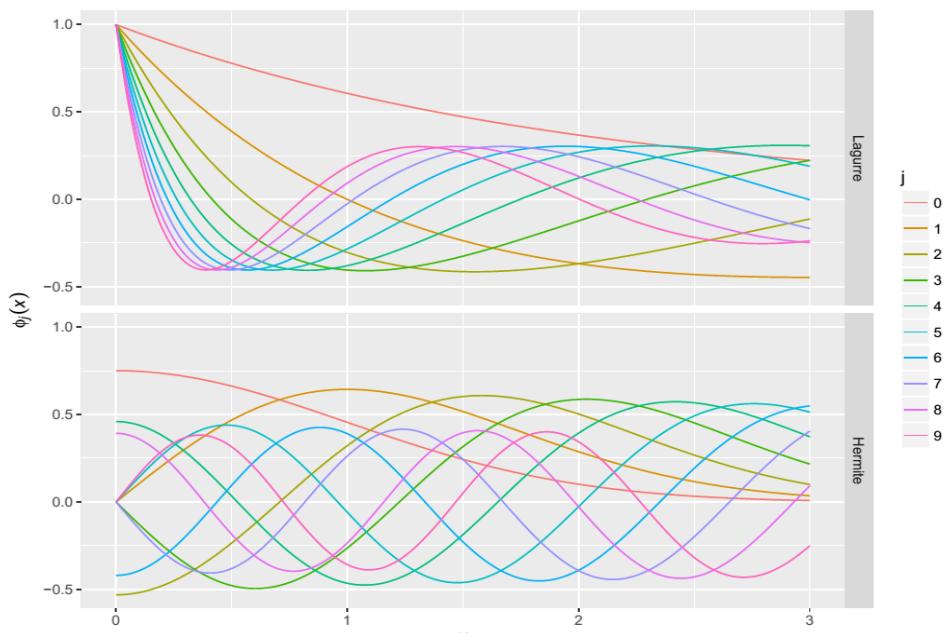
چندجمله‌ای لاغر مرتبه j -ام است، در نظر گرفته می‌شود [۳]. شکل ۱ نمودار ۱۰ تابع نخست دو پایه لاغر و ارمیت نرمال شده را نشان می‌دهد. علاوه بر پایه‌های یکامتعامد رایج، از موجک‌ها^۱ نیز می‌توان استفاده کرد. در این حالت برآوردهای حاصل اغلب برآوردهای موجکی تابع چگالی احتمال نامیده می‌شود (ر.ک. دورروی و لوگوسی [۵] فصل ۱۳).

چنان‌که در بخش ۱ بیان شد، برآوردهای هسته‌ای با هسته‌های استاندارد مانند نرمال، اپانچنیکوف و غیره، به عنوان برآورد توابع چگالی با تکیه‌گاه ($0, \infty$ ، دارای مشکل اریبی (مجانبی) مرزی هستند و استفاده از برآوردهای هسته‌ای گاما و سری‌های متعامد دو راه برای رهایی از این مشکل می‌باشد. برای تبیین بهتر این موضوع، در شکل ۲، تابع چگالی توزیع نمایی با پارامتر $\lambda = 0.2$ و برآوردهای هسته‌ای با هسته‌های اپانچنیکوف و گاما نوی اول و همچنین برآورد با استفاده از سری‌های متعامد در بازه $[0, 1]$ رسم شده است. برای بدست آوردن برآوردها، از یک نمونه ۱۰۰۰ تابی از توزیع نمایی با پارامتر $\lambda = 0.2$ استفاده شده است. با توجه به شکل، مشکل اریبی مرزی برای برآوردهای اپانچنیکوف و برطرف کردن این مشکل با استفاده از دو برآوردهای دیگر مشهود است.

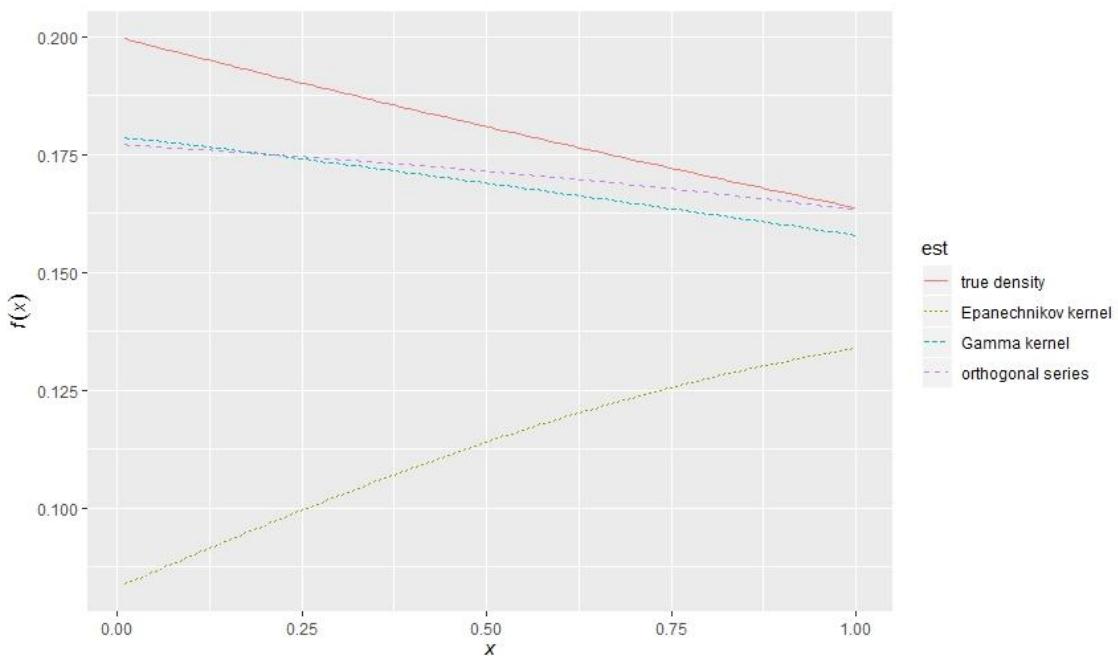
مقایسه برآوردهای

در این بخش، با استفاده از بررسی شبیه‌سازی، برآوردهای هسته‌ای گاما (۳) و (۵) با برآوردهای سری‌های متعامد (۸) برای انواع مختلفی از توابع چگالی با تکیه‌گاه $[0, \infty]$ و با شکل‌های گوناگون در همسایگی صفر مقایسه می‌شوند. مالک و شاینلی [۱۹] از خانواده توزیع‌های تعمیم یافته‌ی F برای مقایسه برآوردهای گاما با برآوردهای ذکرشده در بخش مقدمه استفاده کردند. این خانواده چهار پارامتری از توزیع‌ها دارای تابع چگالی احتمال (۱۰) است:

$$f(x) = \frac{ax^{am} - \left[\eta + \left(\frac{x}{\lambda} \right)^a \right]^{-\eta-m}}{\lambda^{am} B(m, \eta)}, \quad x \geq 0, a, m, \eta, \lambda > 0 \quad (10)$$



شکل ۱. منحنی ۱۰ تابع نخست پایه‌های لاغر و ارمیت نرمال شده به ازای مقادیر $0 \leq x \leq 3$



شکل ۲. تابع چگالی توزیع نمایی و برآورده آن به سه روش هسته اپانچنیکوف و هسته گاما نوع اول و سری‌های متعامد

که در آن $B(m, \eta) = \frac{\Gamma(\eta)\Gamma(m)}{\Gamma(m+\eta)}$. تابع چگالی احتمال (۱۰) از نظر شکل در یک همسایگی نزدیک به صفر بسیار انعطاف‌پذیر است [۳۰]، و از این رو، این خانواده می‌تواند گزینه‌ای مناسب برای مقایسه عملکرد برآوردهای مختلف برای تابع‌های چگالی با تکیه‌گاه $(0, \infty)$ باشد.

مالک و شاینلی [۱۹] با انتخاب ۷ مقدار مختلف برای پارامترهای (a, m, η, λ) به تابع‌های چگالی احتمال مختلفی از خانواده توزیع‌های F تعمیم یافته با رفتارهای گوناگون در همسایگی نزدیک به صفر دست یافتند. مقدارهای در نظر گرفته شده به وسیله مالک و شاینلی [۱۹] برای پارامترهای (a, m, η, λ) ، که منجر به شکل‌های گوناگون تابع چگالی (۱۰) در همسایگی نزدیک به صفر می‌شوند، در جدول ۱ فهرست شده‌اند. مقدار پارامترها طوری انتخاب شده‌اند که این تابع‌های چگالی احتمال دارای امید ریاضی برابر با یک باشند. با این حال تابع چگالی احتمال در حالت D_2 دارای واریانس نامتناهی است زیرا گشتاور مرتبه k ام توزیع تعمیم یافته F برای مقادیر $a\eta < k$ متناهی و برابر با

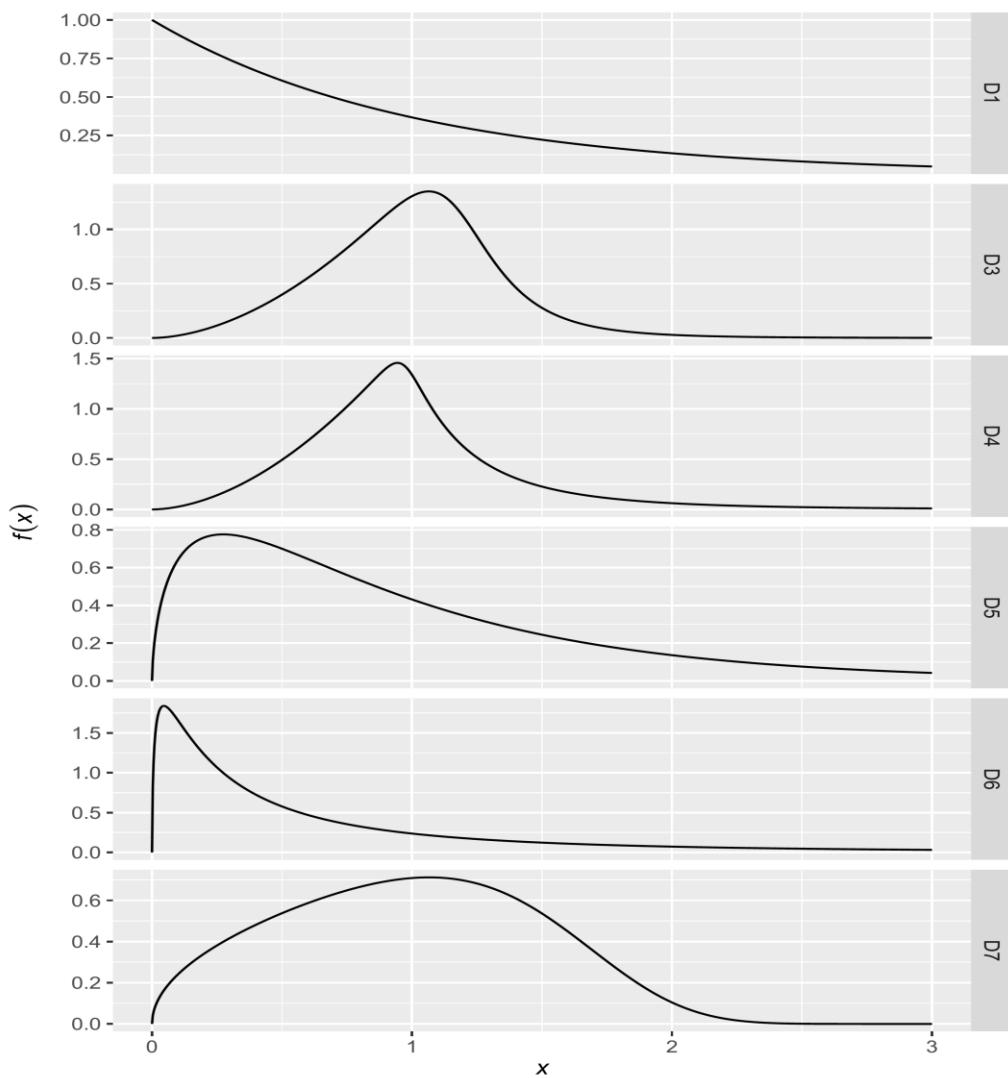
$$\int_0^\infty x^k f(x) dx = \frac{\lambda \eta^{\frac{1}{a}} \Gamma\left(m + \frac{k}{a}\right) \Gamma\left(\eta - \frac{k}{a}\right)}{\Gamma(m) \Gamma(\eta)}$$

و در غیر این صورت نامتناهی است.

جدول ۱. مقادیر در نظر گرفته شده به وسیله مالک و شاینلی [۱۹] برای پارامترهای توزیع تعمیم یافته F

λ	η	m	a	
۱	∞	۱	۱	D_1
۰/۰۹۷	۱/۲	۰/۷	۰/۹	D_2
۱/۲۴	۰/۵	۰/۲	۱۴	D_3
۱/۰۳۵	۰/۱	۰/۰۸	۳۵	D_4
۰/۰۵۹	۰	۳	۰/۵۵	D_6
۱/۶۸	∞	۰/۳	۰/۵	D_7

با صرف نظر کردن از حالت D_2 ، در این بررسی شبیه‌سازی از تابع‌های چگالی احتمال D_1 و D_3 تا D_7 برای مقایسه برآوردهای سری‌های متعامد با برآوردهای گاما استفاده می‌شود. نمودار این تابع چگالی‌ها در شکل ۳ رسم شده است.



شکل ۳. نمودار تابع چگالی توزیع تعمیم یافته F در ۶ حالت در نظر گرفته شده برای شبیه‌سازی

پیش از انجام این مهم، لازم به ذکر است که پارامتر هموارساز ω در \hat{f}_1 و \hat{f}_2 و مقدار بربینشی J در عملکرد این برآوردها بسیار تأثیر گذارند. مقادیر کوچک آنها اریبی کم اما واریانس بزرگ برآوردهای متعانظر را به همراه دارند در حالی که مقادیر بزرگ آنها منجر به نتیجه عکس می‌شوند. بنابراین پارامتر هموارساز ω و مقدار بربینشی J باید به گونه‌ای بهینه انتخاب شوند. یک معیار بهینگی رایج، استفاده از میانگین جمع‌بسته توان دوم خطا است. بر این اساس، پارامتر هموارساز ω و مقدار بربینشی J بهینه با کمینه‌سازی $MISE$ به دست می‌آیند. این انتخاب، مقدار بهینه فراموضعی^۱ نامیده می‌شود. مقدار بهینه فراموضعی پارامتر هموارساز ω در برآوردهای گاما به وسیله چن [۱۶] به دست آمده است؛ اما شکل بسته‌ای برای انتخاب بهینه فراموضعی مقدار بربینشی J در برآوردهای سری‌های متعامد وجود ندارد.

1. Global optimal value

برای تعیین مقادیر بهینه ω و J در برآوردهای \hat{f}_g_1 , \hat{f}_g_2 و \hat{f}_o بر اساس یک نمونه تصادفی نوعی X_1, \dots, X_n ازتابع چگالی هدف f به تعداد $n_{sim} = 5000$ بار نمونه‌هایی با حجم n تولید می‌شود. برای هر نمونه تولید شده X_1, \dots, X_{jn} برآورد $\hat{f}^{(j)}$ برای تابع چگالی احتمال هدف f با برآوردهای هسته گامای (۳) و (۵) و برآوردهای سری‌های متعامد (۸) با پایه‌های لاغر و ارمیت نرمال شده به دست می‌آید. سپس مقدار میانگین جمع‌بسته توان دوم خطابرا برآوردهای هسته گاما به صورت (۱۱)

$$\widehat{MISE}\left(\hat{f}_g(.; \omega)\right) = \frac{1}{n_{sim}} \sum_{j=1}^{n_{sim}} \sum_{l=1}^m \left[f(x_l) - \hat{f}_g^{(j)}(x_l, \omega) \right]^2 \Delta x_l \quad (11)$$

و برای برآوردهای سری‌های متعامد به صورت

$$\widehat{MISE}\left(\hat{f}_o(.; J)\right) = \frac{1}{n_{sim}} \sum_{j=1}^{n_{sim}} \sum_{l=1}^m \left[f(x_l) - \hat{f}_o^{(j)}(x_l) \right]^2 \Delta x_l \quad (12)$$

تقریب زده می‌شود، که در آن $x_0 = 0$ و $x_i = x_i - \frac{i}{m}$ چندک f است. در اینجا $m = 1000$ تعداد نقاطی است که برای تقریب انتگرال موجود در میانگین جمع‌بسته توان دوم خطابا یک مجموع ریمانی به کار گرفته می‌شوند. مقدارهای بهینه ω و J به ترتیب با کمینه‌سازی (۱۱) و (۱۲) به دست می‌آیند. به منظور مقایسه برآوردهای، از تابع چگالی احتمال هر یک از حالت‌های D_1 و D_3 تا D_7 به تعداد $n_{sim} = 5000$ بار نمونه‌هایی به حجم $n = 50, 100, 400$ تولید می‌شوند. مقدارهای بهینه ω و J برای هر یک از نمونه‌های شبیه‌سازی شده به روش بالا به دست می‌آیند و مقدار تقریبی میانگین جمع‌بسته توان دوم خطای هر کدام از برآوردهای متناظر با جای‌گذاری مقدارهای بهینه ω و J در (۱۱) و (۱۲) محاسبه می‌شوند.

برای پیاده‌سازی محاسبات این بررسی شبیه‌سازی از نرم‌افزار و زبان برنامه‌نویسی R و بسته نرم‌افزاری Evmix [۳۱]، برای برآوردهای هسته‌ای گاما، بسته نرم‌افزاری Orthopolynom [۳۲]، برای محاسبات پایه‌های برآوردهای سری‌های متعامد و بسته نرم‌افزاری Flexsurv [۳۳]، برای شبیه‌سازی از خانواده توزیع‌های تعمیم‌یافته استفاده شده است. F

مقدار بهینه پارامتر هموارساز ω برای برآوردهای هسته‌ای گاما \hat{f}_g_1 و \hat{f}_g_2 و مقدار بهینه برینشی J برای برآوردهای سری‌های متعامد با پایه‌های لاغر \hat{f}_o_1 و ارمیت نرمال شده \hat{f}_o_2 ، که به ترتیب با نمادهای ω_1^* , ω_2^* ، J_1^* و J_2^* نمایش داده شده‌اند، در جدول ۲ آمده است. همچنین مقدار تقریبی MISE حاصل برای این برآوردهای نیز در این جدول گزارش شده‌اند.

در حالت D_1 که تابع چگالی هدف رفتاری مشابه با تابع‌های پایه لاغر نرمال شده دارد (شکل ۱ و شکل ۲ را مقایسه کنید)، برآوردهای سری‌های متعامد با پایه لاغر نرمال شده با تعداد بسیار کمی جمله ($J_1^* = 2, 3$) برای همه حجم‌های نمونه مقدار MISE کمتری نسبت به سایر برآوردهای دارد در حالی که برآوردهای سری‌های متعامد با پایه ارمیت نرمال شده به تعداد نسبتاً زیادی جمله ($J_2^* \geq 23$) نیاز دارد و مقدار MISE آن دست کم سه برابر سایر برآوردهای است. به عکس در حالت D_3 و برای همه حجم‌های نمونه، این برآوردهای سری‌های متعامد با پایه ارمیت نرمال شده است که کارایی بهتری (MISE کمتری) نسبت به سایر رقبا دارد، در حالی که برآوردهای سری‌های متعامد با پایه لاغر نرمال شده دارای بدترین عملکرد (بیشترین MISE) است. همچنین تابع چگالی احتمال در حالت D_7 (شکل ۲) به شکل عمومی تابع‌های پایه ارمیت نرمال شده (شکل ۱) نزدیک‌تر است و به همین دلیل در برآوردهای سری‌های متعامد به تعداد کمتری از تابع‌های پایه ارمیت نرمال شده نسبت به پایه لاغر نرمال شده نیاز است

(5). در این حالت برآوردهای سری‌های متعامد با پایه ارمیت نرمال شده کارایی بیشتری نسبت به همین برآوردهای سری‌های متعامد با پایه لاغر نرمال شده دارد.

جدول ۲. پارامتر هموارساز ω و مقدار برینشی J بهینه و میانگین جمع‌بسته توان دوم خطابهای برآوردهای هسته‌گاما \hat{f}_{g_1} و \hat{f}_{g_2} برآوردهای سری‌های متعامد با پایه ارمیت لاغر \hat{f}_{o_1} و پایه ارمیت \hat{f}_{o_2} در برآوردهای تابع‌های چگالی‌های در نظر گرفته شده از خانواده توزیع‌های تعمیم‌یافته F (ر.ک. جدول ۱) با حجم نمونه‌های متفاوت

MISE				پارامتر هموارساز		مقدار برینشی		
\hat{f}_{g_2}	\hat{f}_{g_1}	\hat{f}_{o_2}	\hat{f}_{o_1}	ω_1^*	ω_2^*	J_2^*	J_1^*	n
۰/۰۱۷۷	۰/۰۱۷۳	۰/۰۵۵۱	۰/۰۰۹۲	۰/۲۲۶۴	۰/۱۵۹۷	۲۳	۲	۵۰
۰/۰۱۰۹	۰/۰۱۱۰	۰/۰۴۱۷	۰/۰۰۴۹	۰/۱۷۲۵	۰/۱۱۹۰	۴۷	۲	۱۰۰ D_1
۰/۰۰۳۹	۰/۰۰۴۳	۰/۰۲۲۸	۰/۰۰۱۷	۰/۱۰۲۳	۰/۰۶۶۸	۷۵	۳	۴۰۰
۰/۰۳۶۵	۰/۰۳۷۰	۰/۰۳۳۱	۰/۰۴۴۶	۰/۰۲۲۴	۰/۰۲۱۶	۲۳	۴۷	۵۰
۰/۰۲۲۷	۰/۰۲۳۰	۰/۰۲۲۵	۰/۰۳۰۳	۰/۰۱۵۸	۰/۰۱۵۲	۳۴	۴۷	۱۰۰ D_3
۰/۰۰۸۶	۰/۰۰۸	۰/۰۰۷۶	۰/۰۱۷۶	۰/۰۰۸۱	۰/۰۷۸	۵۵	۴۷	۴۰۰
۰/۰۳۷۷	۰/۰۳۷۶	۰/۰۳۸۴	۰/۰۴۲۸	۰/۰۲۲۹	۰/۰۲۲۰	۲۴	۳۴	۵۰
۰/۰۲۳۹	۰/۰۲۴۲	۰/۰۲۶۱	۰/۰۳۳۸	۰/۰۱۵۵	۰/۰۱۵۱	۳۷	۳۵	۱۰۰ D_4
۰/۰۰۹۳	۰/۰۰۹۳	۰/۰۴۱۸	۰/۰۳۳۷	۰/۰۰۷۳	۰/۰۰۷۳	۷۷	۴۳	۴۰۰
۰/۰۲۰۱	۰/۰۱۸۶	۰/۰۳۲۱	۰/۰۲۱۷	۰/۱۸۰۶	۰/۱۴۲۷	۱۵	۸	۵۰
۰/۰۱۲۹	۰/۰۱۲۳	۰/۰۲۲۵	۰/۰۱۳۱	۰/۰۹۸۰	۰/۰۹۱۷	۲۷	۱۱	۱۰۰ D_5
۰/۰۰۴۸	۰/۰۰۵۱	۰/۰۱۰۳	۰/۰۰۴۴	۰/۰۴۱۵	۰/۳۸۸	۱۵	۱۸	۴۰۰
۰/۰۴۲۲	۰/۰۳۹۲	۰/۱۰۲	۰/۰۳۲۶	۰/۱۰۲۰	۰/۰۷۷۸	۷۱	۶	۵۰
۰/۰۲۶۷	۰/۰۲۵۴	۰/۰۸۰۹	۰/۰۲۱۹	۰/۰۷۴۷	۰/۰۵۳۶	۷۵	۷	۱۰۰ D_6
۰/۰۱۱۵	۰/۰۱۱۰	۱/۲۳۱۵	۰/۱۲۳۸	۰/۰۲۶۵	۰/۰۲۲۶	۷۹	۴۰	۴۰۰
۰/۰۲۱۳	۰/۰۲۲۰	۰/۰۲۷۰	۰/۰۳۴۲	۰/۰۷۴۱	۰/۰۶۸۳	۴	۱۳	۵۰
۰/۰۱۳۳	۰/۰۱۳۹	۰/۰۱۸۰	۰/۰۲۷۳	۰/۰۵۲۸	۰/۰۴۸۶	۶	۲۳	۱۰۰ D_7
۰/۰۰۵۰	۰/۰۰۵۲	۰/۰۰۷۶	۰/۰۱۰۶	۰/۰۲۷۳	۰/۰۲۵۴	۲۰	۳۵	۴۰۰

برای همه حجم‌های نمونه در حالت‌های D_4 و D_7 برآوردهای سری‌های هسته‌ای گاما کارایی بهتری نسبت به برآوردهای سری‌های متعامد دارند. در همه حالت‌ها جز D_6 کارایی برآوردهای گاما \hat{f}_{g_2} نسبت به \hat{f}_{g_1} برای حجم نمونه بزرگ ($n = 400$) اندکی بیشتر از یک است. این امر گواهی دیگری برای پیشنهاد چن [۱۶] در استفاده از برآوردهای \hat{f}_{g_2} به جای \hat{f}_{g_1} برای رسیدن به نرخ هم‌گرایی سریع‌تر MISE برآوردهای هسته‌ای گاما فراهم می‌کند. در حالت D_5 برای حجم نمونه‌های $n = 50, 100$ کارایی برآوردهای گاما \hat{f}_{g_1} و برای حجم نمونه $n = 400$ کارایی برآوردهای سری‌های \hat{f}_{g_2} به جای \hat{f}_{g_1} برآوردهای هسته‌ای گاما فراهم می‌کند. در حالت D_6 برای حجم نمونه‌ای $n = 50$ کارایی برآوردهای هسته‌ای گاما \hat{f}_{g_1} بیشتر است. در حالت D_6 برآوردهای سری‌های متعامد با پایه لاغر برای حجم‌های نمونه $n = 50, 100$ کارایی بیشتری نسبت به سایر برآوردهای سری‌های دارد، اما در

حجم نمونه $n = 400$ مقدار $MISE$ هر دو برآوردهای سری‌های متعامد افزایش می‌یابد و برآوردهای گامای \hat{f}_{g_1} نسبت به سایر برآوردهای کاراتر است. چنان‌که در بخش برآورد سری‌های متعامد اشاره شد، برای اطمینان از هم‌گرایی $MISE$ برآوردهای $\hat{f}_0(.; J)$ به صفر لازم است تابع چگالی هدف f در شرایطی (از جمله متنهای بودن چند گشتاور اول) صدق کند و $J_n = J_n^2$ با نرخی سریع‌تر از n^2 رشد کند. با توجه به مقادیر a و η در حالت D_6 (ر.ک. جدول ۱)، گشتاورهای مرتبه سوم و بالاتر تابع چگالی احتمال در این حالت نامتناهی‌اند و به علاوه مقادیر J_2^* در جدول ۲ با افزایش n به نسبت کند افزایش می‌یابند. به همین دلیل شرایط هم‌گرایی $MISE$ برآوردهای سری‌های متعامد در این حالت برقرار نیست و مقدار $MISE$ برای این برآوردهای افزایش n به 400 به جای کاهش، افزایش داشته است.

بحث و نتیجه‌گیری

در این مقاله عملکرد کوچک‌نمونه‌ای برآوردهای هسته‌ای گاما و سری‌های متعامد با دو پایه لاغر و ارمیت نرمال شده برای برآوردهای ناپارامتری تابع چگالی احتمال یک توزیع نامنفی مقایسه شد. در قالب یک بررسی شبیه‌سازی ملاحظه شد که انتخاب برآوردهای مناسب از بین این دو دسته از برآوردهای منوط به داشتن میزانی از اطلاع در مورد تابع چگالی هدف است. در صورتی که پایه برآوردهای سری‌های متعامد طوری انتخاب شده باشد که تابع‌های آن پایه رفتاری مشابه تابع چگالی هدف داشته باشند، برآوردهای سری‌های متعامد کارایی بیش‌تری نسبت به برآوردهای گاما دارد. اما اگر تابع چگالی هدف در شرایطی که برای سازگاری برآوردهای سری‌های متعامد نیاز است صدق نکند، برآوردهای سری‌های متعامد ممکن است عملکرد نامطلوبی نسبت به برآوردهای هسته‌ای گاما داشته باشند.

تقدیر و تشکر

از داوران محترم که با پیشنهادها و راهنمایی‌های خود مقاله را پربار کردند، کمال تقدیر و تشکر را داریم.

منابع

1. Tapia R. A., Thompson J. R., "Nonparametric Probability Density Estimation", Johns Hopkins University Press, Baltimore (1978).
2. Silverman B. W., "Density estimation for statistics and data analysis", Chapman & Hall/CRC press, London (1986).
3. Izenman A. J., "Review Papers: Recent Developments in Nonparametric Density Estimation", Journal of the American Statistical Association, 86(413) (1991) 205-224.
4. Wand M. P., Jones M. C., "Kernel Smoothing", Chapman and Hall/CRC, London (1995).
5. Devroye L., Lugosi G., "Combinatorial Methods in Density Estimation", Springer Science & Business Media, New York, (2012).
6. Parzen E., "On Estimation of a Probability Density Function and Mode", The Annals of Mathematical Statistics, 33 (3) (1962) 1065-1076.

7. Marron J., Ruppert D., "Transformations to Reduce Boundary Bias in Kernel Density Estimation", *Journal of the Royal Statistical Society. Series B (Methodological)*, 56 (4) (1994) 653-671.
8. Schuster E. F., "Incorporating support constraints into nonparametric estimators of densities", *Communications in Statistics - Theory and Methods*, 14(5) (1985) 1123-1136.
9. Cline D. B. H., Hart J. D., "Kernel Estimation of Densities with Discontinuities or Discontinuous Derivatives", *Statistics*, 22(1) (1991) 69-84.
10. Gasser T., Muller H. G., Mammitzsch V., "Kernels for Nonparametric Curve Estimation", *Journal of the Royal Statistical Society. Series B (Methodological)*, 47 (2) (1985) 238-252.
11. Muller H. G., "Smooth Optimum Kernel Estimators Near Endpoints", *Biometrika*, 78 (3) (1991) 521-530.
12. Muller H. G., "On the boundary kernel method for non-parametric curve estimation near endpoints", *Scand. J. Stat.*, 20 (1993) 313-328.
13. Jones M. C., "Simple boundary correction for kernel density estimation", *Statistics and Computing*, 3(3) (1993) 135-146.
14. Wand M. P., Marron J. S., Ruppert D., "Transformations in Density Estimation", *Journal of the American Statistical Association*, 86 (414) (1991) 343-353.
15. Chen S. X., "Beta kernel estimators for density functions", *Computational Statistics & Data Analysis*, 31 (2) (1999) 131-145.
16. Chen S. X., "Probability Density Function Estimation Using Gamma Kernels", *Annals of the Institute of Statistical Mathematics*, 52 (3) (2000) 471-480.
17. Jones M., Foster P., "A Simple Nonnegative Boundary Correction Method for Kernel Density Estimation", *Statistica Sinica*, 6(4) (1996) 1005-1013.
18. Muller H. G., Wang J. L., "Hazard Rate Estimation under Random Censoring with Varying Kernels and Bandwidths", *Biometrics*, 50(1) (1994) 61-76.
19. Malec P., Schienle M., "Nonparametric Kernel Density Estimation Near the Boundary", *Computational Statistics & Data Analysis*, 72 (2014) 57-76.
20. Karunamuni R. J., Alberts T., "On boundary correction in kernel density estimation", *Statistical Methodology*, 2 (3) (2005) 191-212.
21. Gasser T., Muller H. G., "Kernel estimation of regression functions. In Gasser, T., Rosenblatt, M. (Eds.): Smoothing Techniques for Curve Estimation", *Lecture Notes in Mathematics*, vol. 757. Springer, Heidelberg (1979) 23-68.
22. Cencov N. N., "Estimation of an unknown density function from observations", In Dokl. Akad. Nauk, SSSR Vol. 147 (1964) 45-48.

23. Wahba G., "Data-Based Optimal Smoothing of Orthogonal Series Density Estimates", *The Annals of Statistics*, 9 (1) (1981) 146-156.
24. Hall P., "Cross-validation and the smoothing of orthogonal series density estimators", *Journal of Multivariate Analysis*, 21 (2) (1987) 189-206.
25. Efromovich S., "Orthogonal series density estimation. Wiley Interdisciplinary Reviews: Computational Statistics", 2 (4) (2010) 467-476.
26. Kreyszig E., "Introductory functional analysis with applications", Wiley, New York (1989).
27. Watson G. S., "Density Estimation by Orthogonal Series", *The Annals of Mathematical Statistics*, 40(4) (1969) 1496-1498.
28. Efromovich S., "Nonparametric curve estimation: methods, theory, and applications", Springer Science & Business Media, (2008).
29. Walter G. G., "Properties of Hermite Series Estimation of Probability Density", *The Annals of Statistics*, 5 (6) (1977) 1258-1264.
30. Cox C., "The generalized F distribution: An umbrella for parametric survival analysis", *Statistics in Medicine*, 27 (21) (2008) 4301-4312.
31. Scarrott C. J., Hu Y., "evmix 0.2.7: Extreme Value Mixture Modelling, Threshold Estimation and Boundary Corrected Kernel Density Estimation", Availableon CRAN: <http://www.math.canterbury.ac.nz/~c.scarrott/evmix> (2017).
32. Novomestky F., "orthopolynom 1.0-5: Collection of functions for orthogonal and orthonormal polynomials", Available on CRAN: <https://CRAN.R-project.org/package=orthopolynom> (2013).
33. Jackson C., "flexsurv: A Platform for Parametric Survival Modeling in R", *Journal of Statistical Software*, 70 (8) (2016) 1-33.