

معرفی روش‌های اصلاح کران در برآورد ناپارامتری تابع چگالی و رگرسیون هسته

الهه آخوندزاده کاشانی، مهدیه میرزایی باغینی
گروه آمار، دانشگاه فردوسی مشهد

چکیده

در این مقاله پس از معرفی برآوردگرهای توابع چگالی و رگرسیونی به روش ناپارامتری هسته‌ای، اثرات کران معرفی خواهد شد و در ادامه به معرفی روش‌های اصلاح اثرات کران می‌پردازیم. در انتها نیز دو دلیل استفاده‌ی محدود از این روش‌ها را معرفی خواهیم کرد.

واژه‌های کلیدی: اثرات کران، برآورد ناپارامتری رگرسیون، روش هسته‌ای.

۱ مقدمه

اصلاح کران در هر دو مورد برآورد هسته‌ای توابع چگالی و رگرسیونی ضرورت دارد.

تاکنون روش‌های متعددی برای اصلاح اثرات کران معرفی شده‌اند. در این مقاله چند روش اصلاح اثرات کران معرفی شده‌اند که در ادامه به معرفی چند مورد از آن‌ها می‌پردازیم. ابتدا، برای فهم بهتر مطالب مربوط به اثرات کران، به یادآوری مختصری از بحث برآورد ناپارامتری توابع چگالی و رگرسیونی به روش هسته‌ای خواهیم پرداخت و در ادامه پس از معرفی کلی اثرات کران، به بحث و بررسی بیشتری درباره‌ی روش‌های اصلاح اثرات کران پرداخته می‌شود.

در برآورد توابع چگالی و رگرسیون به روش ناپارامتری افزایش واریانس و اریبی در کران‌ها، که اصطلاحاً اثرات کران نامیده می‌شوند، می‌تواند کاملاً مشکل‌ساز باشد و حتی ممکن است برآوردهای نهایی و در نهایت نتایج را اساساً تغییر دهد. در بسیاری از مطالعات کاربردی کران‌ها مورد توجه خاص هستند، برای مثال در تحلیل فقر، لازم است که برآوردهای قابل اعتمادی از توزیع درآمد در سمت چپ یعنی نزدیک به کران طبیعی صفر داشته باشیم. به طور مشابه وقتی از رگرسیون ناپارامتری در اقتصاد سنجی استفاده می‌شود، اثرات کران نه تنها در کران‌ها بلکه در نزدیک آن‌ها هم دیده می‌شوند. با توجه به این مثال‌ها می‌توان مشاهده کرد که استفاده از روش‌های

۲ برآوردگر هسته‌ای تابع چگالی

جدول ۱: توابع هسته مختلف

هسته	$K(u)$
یکنواخت	$\frac{1}{2}I(u \leq 1)$
مثلث	$(1 - u)I(u \leq 1)$
اپنیچ نیکوف	$\frac{3}{4}(1 - u^2)I(u \leq 1)$
درجه‌ی چهارم (دو وزنی)	$\frac{15}{16}(1 - u^2)^2I(u \leq 1)$
سه وزنی	$\frac{35}{32}(1 - u^2)^3I(u \leq 1)$
گوسی	$\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}u^2\right)$
کسینوس	$\frac{\pi}{4} \cos\left(\frac{\pi}{4}u\right)I(u \leq 1)$

فرض کنید نمونه تصادفی X_1, X_2, \dots, X_n را به حجم n از توزیعی پیوسته و نامعلوم داریم. در این صورت برآورد تابع چگالی f در فاصله‌ی $[x-h, x+h]$ به طول $2h$ توسط $\hat{f}_h(x)$ در عبارت (۱) محاسبه می‌شود.

$$\hat{f}_h(x) = \frac{1}{2nh} \# \{X_i \in [x-h, x+h]\}, \quad (1)$$

که در آن $\#$ به مفهوم تعداد مشاهدات قرار گرفته در بازه مورد نظر می‌باشد.

اگر در این عبارت از تابع وزنی

$K(u) = \frac{1}{2}I(|u| \leq 1)$ ، $u = (x - X_i)/h$ استفاده شود، می‌توان عبارت (۱) را به صورت عبارت (۲)

بازنویسی کرد:

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right) \quad (2)$$

$$= \frac{1}{nh} \sum_{i=1}^n \frac{1}{2} I\left(\left|\frac{x - X_i}{h}\right| \leq 1\right). \quad (3)$$

K مختصرنویسی یک تابع وزنی به نام تابع هسته‌ی یکنواخت است که به هر مشاهده X_i که فاصله آن از x (نقطه‌ای که می‌خواهیم تابع چگالی احتمال را برآورد کنیم) کمتر از h است وزن $1/2$ را تخصیص می‌دهد و مشاهداتی که فاصله آن‌ها از x بیشتر از h است وزن صفر می‌گیرند.

توابع هسته‌ی متقارن تابعی با تکیه‌گاه $[-1, 1]$ هستند که در $\mu_0(K) = 1$ و $\mu_1(K) = 0$ با $\mu_l(K) = \int_{-1}^1 u^l K(u) du$ ($l = 0, 1, 2; u = \frac{x - X_i}{h}$) صدق می‌کنند. تاکنون توابع هسته‌ی متعددی معرفی شده‌اند که تعدادی از آن‌ها در جدول ۱ معرفی شده‌اند.

اکنون می‌توان فرم کلی برآوردگر هسته‌ای تابع چگالی احتمال در نقطه x را معرفی نمود. بر همین اساس با توجه به یک نمونه تصادفی X_1, X_2, \dots, X_n از f داریم:

$$\hat{f}_h(x) = \frac{1}{n} \sum_{i=1}^n K_h(x - X_i), \quad (4)$$

که

$$K_h(\cdot) = \frac{1}{h} K(\cdot/h), \quad (5)$$

(●) K یک تابع هسته مشابه آنچه در جدول ۱ نمایش داده شده است، می‌باشد و h پهنا‌ی باند را مشخص می‌کند. توجه کنید که عبارت "تابع هسته" اشاره به تابع وزنی K دارد، در حالی که برآوردگر هسته‌ای چگالی اشاره به فرمول (۴) دارد.

۳ رگرسیون هسته‌ای

سوال مهمی که در بسیاری از زمینه‌های علمی مطرح است، چگونگی رابطه‌ی بین دو متغیر می‌باشد که X و Y نامیده می‌شوند. تحلیل رگرسیونی به این سوال که چگونه Y (متغیر وابسته) می‌تواند توسط X (متغیر مستقل یا

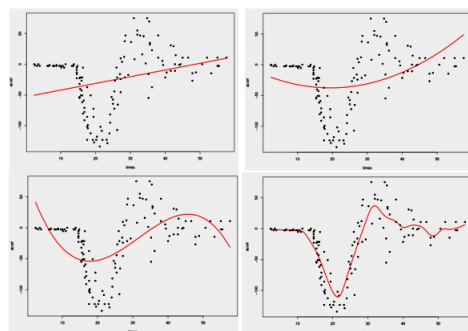
توضیحی) توضیح داده شود، پاسخ می‌دهد. این به معنی رابطه‌ای به فرم:

$$Y = m(X),$$

است که $m(\bullet)$ در مفهوم ریاضی یک تابع است. اکثراً در فرضیات علمی هیچ قیدی بر فرم تابعی $m(\bullet)$ تحمیل نمی‌شود. یعنی، در فرضیات بیان نمی‌شود که آیا $m(\bullet)$ خطی، درجه دو، نسبت به X صعودی یا غیره است. از این رو یافتن اطلاعات بیشتر در مورد $m(\bullet)$ تا حدودی یک تحلیل تجربی است.

خاطر نشان می‌کنیم که در روش‌های پارامتری اغلب فرض می‌شود $m(x) = \alpha + \beta x$ و مسئله برآورد $m(x)$ به مسئله برآورد α و β ساده می‌شود. اما این روش در برخی موارد که داده‌ها فرم تابعی پیچیده‌ای دارند مفید نیست، از این رو در روش‌های ناپارامتری چنین قیدهایی روی $m(\bullet)$ در نظر گرفته نمی‌شود.

مثال ۱.۳. به منظور درک بهتر این مسئله شکل ۱ را در نظر بگیرید. این نمودار مربوط به داده‌های تصادفات موتورسواران در نرم‌افزار R می‌باشد.



شکل ۱: برازش خطی (بالا سمت چپ)، برازش درجه دو (بالا سمت راست) رگرسیون درجه سه (پایین سمت چپ)، رگرسیون هسته‌ای (پایین سمت راست)

نتایج شکل ۱ مؤید این نکته است که رگرسیون ناپارامتری بدون در نظر گرفتن هیچ‌گونه قیدی روی $m(\bullet)$ بهترین نمودار را به داده‌ها برازش می‌دهد.

هنگامی که X و Y هر دو متغیرهای تصادفی با تابع چگالی احتمال توأم $f(x, y)$ باشند، طرح نمونه‌گیری برای استخراج n جفت $\{(X_i, Y_i)\}$ ، طرح تصادفی نام دارد، از این رو می‌توان با تعریف امید شرطی، برآوردگر رگرسیونی را به صورت زیر محاسبه کرد:

$$m(x) = E(Y | X = x) = \int y \frac{f(x, y)}{f_X(x)} dy = \frac{\int y f(x, y) dy}{f_X(x)}, \quad (۶)$$

با این فرض که مشاهداتی به فرم $\{X_i, Y_i\}, i = 1, 2, \dots, n$ داریم، تنها کمیت‌های نامعلوم در سمت راست عبارت (۶)، $f(x, y)$ و $f_X(x)$ هستند. با توجه به مباحث مربوط به برآورد چگالی هسته، می‌دانیم چگونه توابع چگالی احتمال را برآورد کنیم. برآورد $f_X(x)$ سراسر است (با استفاده از عبارت (۴)). برای برآورد $f(x, y)$ می‌توان از برآوردگر چگالی چند-متغیره با هسته ضربی که به صورت زیر تعریف می‌شود، استفاده کرد.

$$\kappa(u) = K(u_1) \dots K(u_d),$$

که در آن $\kappa(u) = \kappa(u_1, \dots, u_d)$ تابع هسته‌ای چند بعدی است و $K(u_1), \dots, K(u_d)$ معرف توابع هسته یک متغیره هستند. از این رو داریم:

$$\hat{f}_{h,g}(x, y) = \frac{1}{n} \sum_{i=1}^n K_h\left(\frac{x - X_i}{h}\right) K_g\left(\frac{y - Y_i}{g}\right). \quad (۷)$$

بر اساس برآورد معرفی شده برای تابع چگالی توأم به

روش هسته، می‌توان نشان داد:

به صورت زیر محاسبه می‌شود (اثبات در [۱]):

$$\text{Bias} \{ \hat{f}_h(x) \} = \frac{h^\nu}{\nu} f^{(\nu)}(x) \mu_\nu(K) + o(h^\nu), \text{ as } h \rightarrow 0 \quad (9)$$

$$\text{Var} \{ \hat{f}_h(x) \} = \frac{1}{nh} \|K\|_\nu^2 f(x) + o\left(\frac{1}{nh}\right), \text{ as } nh \rightarrow \infty \quad (10)$$

$$\int y \hat{f}_{h,g}(x, y) dy = \frac{1}{n} \sum_{i=1}^n K_h(x - X_i) Y_i$$

با قرار دادن عبارت بالا در معادله (۶)، برآوردگر به دست می‌آید که توسط ناداریا [۶] و واتسون [۱۰] به صورت زیر معرفی شد:

$$\hat{m}_h(x) = \frac{n^{-1} \sum_{i=1}^n K_h(x - X_i) Y_i}{n^{-1} \sum_{j=1}^n K_h(x - X_j)} \quad (8)$$

که در آن $\mu_\nu(K) = \int s^\nu K(s) ds$ و $\|K\|_\nu^2 = \int K^\nu(s) ds$.
قضیه ۲.۴. اریبی و واریانس برآوردگر ناداریا-واتسون به صورت زیر محاسبه می‌شود (اثبات در [۱]):

$$\text{Bias}(\hat{m}) = \frac{h^\nu \mu_\nu(K)}{\nu f(x)} (m^{(\nu)}(x) f(x) + f'(x) m'(x)) + O\left(\frac{1}{nh}\right) + o(h^\nu)$$

$$V(\hat{m}) = \frac{\sigma^2(x)}{nh f(x)} \|K\|_\nu^2 + O\left(\frac{1}{nh}\right),$$

$$\sigma^2(x) = V[Y_i | X_i = x]$$

۴ روش‌های اصلاح کران

در این بخش به معرفی برخی از مهمترین روش‌های اصلاح کران پرداخته می‌شود.

۱.۴ اثرات کران

در این جا ذکر این نکته لازم است که در نواحی کرانی اریبی از مرتبه‌ی $o(h)$ است که تا حدی بدتر از اریبی مرتبه‌ی $o(h^\nu)$ در ناحیه درونی تکیه‌گاه است. در تمام این محاسبات (برآورد چگالی و برآورد رگرسیونی) فرض شده است که تکیه‌گاه تابع چگالی دامنه اعداد حقیقی باشد. اگر این فرض برقرار نباشد و به عنوان مثال برآورد هسته‌ای تابع چگالی برای داده‌ها روی اعداد حقیقی مثبت انجام گیرد، نزدیک کران تکیه‌گاه (در مبدأ مختصات) واریانس و اریبی برآوردگر افزایش می‌یابد. این مسئله بدین علت است که برآوردگر هسته‌ای تابع چگالی دانشی در مورد کران ندارد و به طور کلی، جرم احتمال را به خارج از تکیه‌گاه اختصاص می‌دهد و برای تمام نقاط x که در کران‌ها قرار دارند، جستجوی هسته سهواً برای

فرض کنید می‌خواهیم تابع چگالی احتمال f را به صورت ناپارامتری براساس یک نمونه تصادفی به حجم n یعنی به صورت x_1, x_2, \dots, x_n برآورد کنیم. با توجه به مطالب ذکر شده در بخش ۲، برآوردگر هسته‌ای چگالی استاندارد f توسط معادله‌ی (۴) محاسبه می‌شود. برای قابل قبول بودن روش هسته فرض می‌شود f تابعی هموار است و مشتق مرتبه‌ی دوم آن موجود است. اریبی و واریانس برآوردگر چگالی هسته و برآوردگر ناداریا و واتسون برای تابع رگرسیونی طبق قضایای زیر محاسبه می‌شود.

قضیه ۱.۴. اریبی و واریانس برآوردگر هسته‌ای چگالی

- اطلاعات خارج از تکیه‌گاه f صورت می‌گیرد. افزایش
- وارianس و اریبی در کران‌ها در اصطلاح "اثرات کران" نامیده می‌شود. در مورد رگرسیون ناپارامتری نیز، مسئله اثرات کران مشهود است و در عمل می‌تواند به‌عنوان یک مسئله جدی مطرح شود و برآورد صورت گرفته را تحت تاثیر قرار دهد.
- روش انعکاس داده‌ها (اسکاتر^۲[۸])
- روش شبه داده (کولینگ و هال^۳[۲])
- روش هسته‌های کرانی (ژانگ و کارونامونی^۴[۱۱])
- روش پهنای باند محلی (رایس^۵[۷])

۲.۴ روش تبدیل داده‌ها

در این روش برآوردگر هسته‌ای چگالی به صورت زیر تعریف می‌شود:

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - g(X_i)}{h}\right),$$

که در آن $g : [0, \infty) \rightarrow [0, \infty)$ تابعی پیوسته و یک به یک است و K برآوردگر هسته‌ای معمولی می‌باشد. توجه کنید که این برآوردگر در حقیقت برآوردگر تابع چگالی احتمال X نیست، بلکه برآوردگر $g(X)$ است.

۳.۴ روش انعکاس داده‌ها

با توجه به مطالب ذکر شده در بخش ۱.۴، اگر برآورد هسته‌ای تابع چگالی برای داده‌ها روی اعداد حقیقی مثبت انجام گیرد، به دلیل عدم وجود داده در محور منفی اثرات کران افزایش می‌یابد. از این رو، ایده اصلی این روش براساس اضافه کردن $-X_1, -X_2, \dots, -X_n$ به مجموعه‌ی داده‌هاست، بنابراین می‌توان تابع چگالی را در این روش با استفاده از عبارت (۱۱) برآورد کرد.

$$\hat{f}(x) = \begin{cases} \frac{1}{nh} \sum_{i=1}^n \left\{ K\left(\frac{x-X_i}{h}\right) + K\left(\frac{x+X_i}{h}\right) \right\} & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (11)$$

به‌عنوان مثال در مورد بررسی فقر در یک جامعه، لازم است تا برآورد قابل قبولی از توزیع درآمد در سمت چپ، نزدیک کران طبیعی صفر، داشته باشیم. به همین ترتیب اگر علاقه‌مند به تحلیل ریسک، فقر و نابرابری باشیم به ترتیب باید به گروه‌های سنی (جوان یا پیر)، تفاوت در میزان تحصیلات و مقایسه‌ی شرکت‌های بزرگ و کوچک و ... بپردازیم. بنابراین در موارد بسیاری روی کران‌ها تمرکز داریم. در این مقاله نواحی کرانی چپ و راست به ترتیب توسط B_1 و B_r نمایش داده می‌شوند و به صورت زیر تعریف می‌شوند:

$$B_1 = \{x : a \leq x < (a + h)\},$$

$$B_r = \{x : (c - h) < x \leq c\},$$

که در آن (h) به پهنای باند اشاره دارد و $-a$ در صورت وجود، کران پایین است و کران بالا، در صورت وجود توسط c نمایش داده می‌شود، از این رو $[a + h, c - h]$ ناحیه درونی می‌باشد.

تاکنون روش‌های متعددی برای اصلاح اثرات کران معرفی شده‌اند، به طور کلی روش‌های موجود می‌تواند به گروه‌های زیر تقسیم شود:

- روش تبدیل داده‌ها (واند و همکاران^۱[۹])

^۲Schuster

^۳Cowling and Hall

^۴Zhang and Karunamuni

^۵Rice

^۱Wand et al.

۴.۴ روش شبه داده

۵.۴ روش هسته‌های کرانی

در این زیربخش، روش شبه داده کولینگ و هال [۲] معرفی می‌شود که در واقع نوعی از برآوردگر تبدیل یافته‌ی انعکاسی است، در این روش ابتدا داده‌ها به مجموعه‌ای جدید تبدیل می‌شوند و سپس این داده‌ها در محور منفی قرار می‌گیرند. کولینگ و هال برآوردگر تابع چگالی را به صورت زیر معرفی کردند:

$$\hat{f}(x) = \frac{1}{nh} \left\{ \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right) + \sum_{i=1}^m K\left(\frac{x - X_{-i}}{h}\right) \right\}, \quad (12)$$

که m به گونه‌ای است که $O(nh) < O(m) < O(n)$ و همچنین متغیر X_{-i} برای ثابت‌های مثبت r که $A_1, \dots, A_s (s \geq r)$ به همواری تابع چندک X در لبه‌ی مورد نظر وابسته است) و اعداد حقیقی a_1, \dots, a_s به صورت زیر تعریف می‌شود:

$$X_{-i} = \sum_{j=1}^s a_j X_{A_j i}, \quad 1 \leq i \leq \frac{n}{\max\{A_i\}}$$

به طوری که

$$\sum_{k=1}^s a_k A_k^j = (-1)^j, \quad 1 \leq j \leq r \quad (13)$$

در مقاله کولینگ و هال [۲] X_{-i} توسط قانون "بهترین سه نقطه" به صورت زیر محاسبه می‌شود:

$$X_{-i} = -5X_{(i/3)} - 4X_{(2i/3)} + 10/3 X_{(i)}, \quad i = 1, 2, \dots, n.$$

ژانگ و کارونامونی [۱۱] هسته‌های کرانی با پهنای باند متغیر را به صورت زیر معرفی کردند. در این روش برای برآورد تابع چگالی در هر نقطه‌ای که در ناحیه کرانی قرار بگیرد از یک هسته‌ی متفاوت استفاده می‌شود که معمولاً هسته‌های جدید فاقد ویژگی تقارن هستند و روی محور مثبت وزن بیشتری می‌گیرند. بر این اساس برآوردگر به صورت زیر نمایش داده می‌شود:

$$\hat{f}(x) = \frac{1}{nh_c} \sum_{i=1}^n K_{(c/b(c))} \left(\frac{x - X_i}{h_c} \right), \quad (14)$$

که در رابطه بالا از $c = \min\{x/h, 1\}$ در ناحیه کرانی استفاده می‌شود و $b(c) = 2 - c$ است. همچنین هسته‌ی کرانی استفاده شده در رابطه فوق عبارت است از:

$$K_{(c)}(t) = \frac{12}{(1+c)^4} (1+t) \left\{ (1-2c)t + \frac{3c^2 - 2c + 1}{2} \right\} I\{-1 \leq t \leq c\}.$$

ژانگ و کارونامونی [۱۱] نشان دادند که این هسته در زمینه‌ی مینیمم ساختن MSE بین کلاس تمامی هسته‌ها بهینه است.

۶.۴ روش پهنای باند محلی

یک روش دیگر، انتخاب پهنای باند محلی در ناحیه کران است. به ویژه ممکن است این نظر وجود داشته باشد که در نواحی کرانی باید از پهنای باند بزرگ‌تر استفاده کرد. رایس [۷] و گسر و همکاران [۳] پهنای باندی را پیشنهاد دادند که در کران ثابت است. برای دستیابی به این مسئله، در حقیقت برای تمام نقاط کران

اغلب این روش‌ها با روش اصلاح کرانی که توسط جونز^۶ معرفی شده، مقایسه می‌شوند. در این بخش روش جونز معرفی شده و ویژگی‌های واریانس و اریبی آن نیز نمایش داده می‌شود. جونز پیشنهاد کرد که هسته‌ی استفاده شده در این برآورد (به ویژه اگر تابع f روی $[a, c]$ تعریف شده باشد) به صورت زیر تعریف می‌گردد:

$$K^*(u) = \frac{w_2 - w_2 u}{w_1 w_2 - (w_2)^2} K(u) 1_{[c_1, c_2]}, \quad (17)$$

به عبارت دیگر جونز پیشنهاد کرد که توان بیشتری از درون تکیه‌گاه بگیریم، به طوری که مؤلفه‌های دوباره نرمال شده‌ی w_j به صورت زیر تعریف می‌گردد:

$$w_j = \int_{c_1}^{c_2} \left(\frac{t-x}{h_{global}} \right)^{j-1} K \left(\frac{t-x}{h_{global}} \right) dt,$$

که $c_2 = \max(a, x - h_{global})$ و $c_1 = \min(c, x + h_{global})$ می‌باشند. پس برآورد تابع چگالی بر اساس این روش جهت اصلاح اثرات کران، با به کارگیری هسته به طور خطی اصلاح شده $K^*(u)$ در رابطه (۴) به دست می‌آید. به طور مشابه برای برآورد رگرسیونی (۱۱) از $K^*(u)$ در تعریف $\hat{m}_h(x)$ استفاده خواهیم کرد.

حال مجانب‌های برآوردگر هسته وقتی روش جونز [۵] به کار رفته است را در نظر بگیرید. بدون کاستن از کلیت فرض کنید کران پایین a را داریم، به خاطر دارید که پذیرفتم هسته‌ها روی $[-1, 1]$ کراندار هستند. در این جا اندیس $global$ از پهناى باند حذف شده است و ضمناً اسکالر p را که به x و a از طریق $x = p(a + h)$ وابسته

یک پهناى باند محلی استفاده می‌شود که به صورت زیر تعریف می‌شود:

$$h_x = \begin{cases} 2h_{global} - (x - a) & a < x < (a + h_{global}), \\ 2h_{global} - (c - x) & (c - h_{global}) < x < c, \\ h_{global} & \text{سایر جاها} \end{cases} \quad (15)$$

هال و ورلی [۴] این ایده را ابتدا بر روی داده‌های شبیه‌سازی شده توسعه دادند (با یک نوع از بوت-استرپ) و سپس برآورد را در ناحیه کران با استفاده از مجموعه‌ای از داده‌های حقیقی و داده‌های فرضی قبلی انجام دادند.

در زمینه‌ی برآورد تابع رگرسیونی $m(\bullet)$ ، رایس (۱۹۸۴) برای تمام نقاط کرانی $\rho < x = a + h\rho$ ، ۱ برآوردگر (۱۶) را پیشنهاد کرد که ترکیبی خطی از برآوردگرهای اصلاح نشده $\hat{m}_{h_{global}}$ و برآوردگرهای اصلاح شده \hat{m}_{h_x} است.

$$\tilde{m}(x) = (1 + \beta_\rho) \hat{m}_{h_{global}}(x) - \beta_\rho \hat{m}_{h_x}(x), \quad (16)$$

که \hat{m} در (۸) تعریف شده و h_x بر اساس رابطه (۱۵) انتخاب می‌شود.

$$\beta_\rho = \frac{w_1(\rho) w_0^{-1}(\rho)}{(2 - \rho) w_1 \left(\frac{\rho}{2 - \rho} \right) - w_1 w_0^{-1}},$$

$$w_k(v) = \int_{-1}^v u^k K(u) du.$$

۷.۴ روش جونز

همانگونه که اشاره شد اکنون روش‌های اصلاح کران متعددی برای برآوردگر هسته‌ای چگالی موجود است اما

^۶ Jones

چگالی و رگرسیون هسته. پایان نامه کارشناسی ارشد، دانشگاه فردوسی مشهد.

است، تعریف شده است. پس برای

$$a_1(p) = \int_{-1}^{\min[1,p]} u^1 K(u) du$$

و

$$b(p) = \int_{-1}^{\min[1,p]} K^2(u) du,$$

مجانب‌ها می‌توانند توسط معادلات زیر تخمین زده شوند:

$$\text{Bias} \{ \hat{f}_h(x) \} \simeq f(x) (a_0(p) - 1) - h a_1(p) f'(x) + \frac{h^2}{2} f''(x) a_2(p), \quad (18)$$

$$\text{var} \{ \hat{f}_h(x) \} \simeq \frac{1}{nh} f(x) b(p). \quad (19)$$

توجه داشته باشید که برای تمام نقاط درونی، مجانب‌ها به ترتیب با عبارات عمومی (۹) و (۱۰) برابرند.

در نهایت می‌توان ذکر کرد که علیرغم اهمیت زیاد روش‌های اصلاح کران در عمل و همچنین اهمیت قابل توجه (اما نه زیاد) آن‌ها در مطالعات نظری، این روش‌ها هم در برآورد چگالی و هم در رگرسیون به ندرت استفاده می‌شوند. یک دلیل واضح این امر، فقدان برنامه‌های اجرایی در نرم‌افزارهای آماری و اقتصادی است. در کنار فقدان نرم‌افزار دلیل دیگر برای استفاده اندک از این روش‌ها می‌تواند پیچیدگی آن‌ها در مقایسه با میزان بهبود مشهود ایجاد شده در برآورد نهایی باشد.

مراجع

[2] Cowling, A. and Hall, P. (1996).

On pseudodata methods for removing boundary effects in kernel density estimation. Journal of the Royal Statistical Society, Series B, 58 (3), 551-563.

[3] Gasser, T., Müller, H. G. and Mammen, V. (1985).

Kernels for nonparametric curve estimation. Journal of the Royal Statistical Society, Series B 47 (2), 238-252.

[4] Hall, P. and Wehrly, T. E. (1991).

A geometrical method for removing edge effects from kernel-type nonparametric regression estimators. Journal of the American Statistical Association, 86 (415), 665-672.

[5] Jones, M. C. (1993).

Simple boundary correction in kernel density estimation. Statistics and Computing, 3, 135-146.

[6] Nadaraya, E. A. (1964).

On estimating regression. Theory of Probability and its Applications, 10, 186-190.

[۱] آخوندزاده کاشانی، ا. (۱۳۹۱). معرفی روشی ساده

و موثر برای اصلاح کران در برآورد ناپارامتری تابع

- [7] Rice, J. (1984). Boundary modification for kernel regression. *Communications in Statistics Theory and Methods*, 13 (7), 893-900.
- [8] Schuster, E. F. (1985). Incorporating support constraints into non-parametric estimators of densities. *Communications in Statistics. Theory and Methods*, 14(5), 1123-1136.
- [9] Wand, M. P., Marron, J. S. and Ruppert, D. (1991). Transformations in density estimation. *Journal of the American Statistical Association*, 86 (414), 343-353.
- [10] Watson, G. S, (1964). Smooth Regression Analysis, *Sankhya*, 26:15, 175-184.
- [11] Zhang, S. and Karunamuni, R. J. (1998). On kernel density estimation near endpoints. *Journal of Statistical Planning and Inference*, 70, 301-316.