

## ЛИТЕРАТУРА

1. Мишев Д. Дистанционное исследование Земли из космоса: Пер. с болг.—М.: Мир, 1985.
2. Аэрокосмические исследования Земли.—М.: Наука, 1979.
3. Исследование природной среды с пилотируемых орбитальных станций.—Л.: Гидрометеопиздат, 1972.
4. Прэтт У. Цифровая обработка изображений.—М.: Мир, 1982.
5. Abuja N., Schacter B. J. Image models // ACM Comput. Surv.—1981.—V. 13, N 4.—P. 373.
6. Kashyap R. L. Analysis and synthesis of image patterns by spatial interaction models // Progress in Pattern Recognition/Ed. L. M. Kanal, A. Rosenfeld.—Amsterdam; New York; Oxford: North-Holland Publishing Company, 1981.
7. Кендалл М., Моран П. Геометрические вероятности.—М.: Наука, 1972.
8. Gelis A., Boots B. Models of Spatial Processes.—L., Cambridge, 1978.
9. Иванов В. А., Иванченко Г. А. Математическое обеспечение статистического анализа аэрофотоснимков леса // Автометрия.—1982.—№ 4.
10. Косых В. П., Пустовских А. И., Тарасов Е. В., Яковенко Н. С. Морфологический процессор // Там же.—1984.—№ 4.
11. Mandelbrot B. B., Van Ness J. W. Fractional brownian motions, fractional noises and applications // SIAM Rev.—1968.—V. 10, N 4.—P. 422.
12. Mandelbrot B. B. Fractals: Form, Chance and Dimension.—San Francisco: Freeman, 1977.
13. Fournier A., Fussell D., Carpenter L. Computer rendering of stochastic models // Commun. ACM.—1982.—V. 25, N 6.—P. 371.
14. Woods J. W. Two-dimensional discrete markovian fields // IEEE Trans. of Inf. Theory.—1972.—V. IT-18, N 2.—P. 232.

*Поступила в редакцию 5 октября 1987 г.*

УДК 519.24

**В. Г. АЛЕКСЕЕВ**

(Москва)

### О ВЫБОРЕ ПАРАМЕТРОВ ОЦЕНКИ КРИВОЙ РЕГРЕССИИ С ПОМОЩЬЮ ПЕРЕКРЕСТНОЙ ПРОВЕРКИ

Статистическое оценивание кривой регрессии является одной из тех немногих задач, где сама «природа» идет навстречу исследователю, помогая ему в выборе параметров оценки таким образом, чтобы ошибка оценивания в условиях данного эксперимента была близка к минимальной. Решающая роль в корректировке параметров оценки искомой функции регрессии с помощью самой выборки принадлежит методу перекрестной проверки, описанному, например, в [1, 2]. В настоящей работе метод перекрестной проверки применен к непараметрической оценке, зависящей от двух функциональных и двух числовых параметров.

Итак, пусть  $(\xi, \eta)$  — двумерная случайная величина с плотностью вероятности  $f(x, y)$  и

$$\lambda(x) = \langle \eta | \xi = x \rangle = \int y f(x, y) dy / \int f(x, y) dy. \quad (1)$$

Здесь (и всюду в дальнейшем) интеграл без указания пределов обозначает интегрирование в пределах от  $-\infty$  до  $+\infty$ , а угловые скобки  $\langle \rangle$  являются символом математического ожидания.

Оценку величины  $\lambda(x)$  по выборке  $\{(\xi_i, \eta_i), i = 1, \dots, n\}$  из  $n$  независимых наблюдений случайной величины  $(\xi, \eta)$  будем искать в виде

$$\lambda_n(x) = \sum_{i=1}^n \left[ \eta_i v \left( \frac{\xi_i - x}{b} \right) / nb \right] / \sum_{i=1}^n \left[ u \left( \frac{\xi_i - x}{a} \right) / na \right], \quad (2)$$

где ядра (весовые функции)  $u(x)$  и  $v(x)$ ,  $x \in R = (-\infty, \infty)$ , четны, ограничены, тождественно обращаются в нуль вне интервала  $(-1, 1)$  и

нормируются условием

$$\int_{-1}^1 u(x) dx = \int_{-1}^1 v(x) dx = 1,$$

а масштабные множители (параметры размытости)  $a = a(n)$  и  $b = b(n)$  положительны.

Наиболее существенное отличие предлагаемой нами оценки (2) от оценки, рассмотренной в работах [1, 2] и многих других, состоит в том, что параметры  $v(\cdot)$  и  $b$ , стоящие в числителе (2), могут не совпадать с параметрами  $u(\cdot)$  и соответственно  $a$ , стоящими в знаменателе. Пусть  $p_n(x)$  и  $\gamma_n(x)$  — знаменатель и числитель правой части формулы (2). Величины  $p_n(x)$  и  $\gamma_n(x)$  могут рассматриваться как оценки знаменателя  $p(x) = \int f(x, y) dy$  и числителя  $\gamma(x) = \int yf(x, y) dy$  правой части формулы (1). При этом параметры обеих статистических оценок желательно было бы выбирать независимо в соответствии с теми или иными предположениями относительно степени гладкости функций  $p(x)$  и  $\gamma(x) = \lambda(x)p(x)$ . Здесь, однако, нельзя забывать о том, что величина  $p_n(x)$ , оценивающая плотность вероятности  $p(x)$  случайной величины  $\xi$ , стоит в знаменателе оценки (2). Это накладывает на выбор параметров оценки (2) определенные ограничения. Легко видеть, что оценка (2) будет иметь смысл при любых значениях аргумента  $x$ , если

$$b \leq a \text{ и } u(x) > 0 \text{ для всех } x \in (-1, 1). \quad (3)$$

Что же касается ядра  $v(x)$ , то оно может быть выбрано и знакопеременным, т. е. принимающим на интервале  $(-1, 1)$  как положительные, так и отрицательные значения. Введем в рассмотрение порядок  $r$ ,  $r = 2, 4, \dots$ , ядра  $v(x) = v_r(x)$ , определяемый как наименьшее четное число  $k$ , для которого

$$\int_{-1}^1 x^k v(x) dx \neq 0.$$

Применение ядер  $v_r(x)$  высших порядков (т. е. порядков  $r > 2$ ) может привести к многократному уменьшению ошибки оценивания, если: а) оцениваемая функция  $\gamma(x)$  имеет непрерывные производные достаточно высоких порядков и б) объем выборки  $n$  не слишком мал. При этом с ростом объема выборки  $n$  растет как порядок  $r$  оптимального ядра  $v(x)$ , так и достигаемый с его помощью выигрыш в точности оценивания (по этому поводу см., например, работы [3, 4], посвященные родственным задачам непараметрического оценивания). Различные наборы весовых функций  $v_r(x)$ ,  $r = 2, 4, \dots$ , могут быть найдены в [5, 6]. Исследователю, впервые вступающему на путь применения знакопеременных весовых функций, может быть рекомендован набор  $v_r(x)$ ,  $r = 2, 4, \dots$ , начинающийся с функций

$$\begin{aligned} v_2(x) &= (3/4)(1 - x^2)g(x); \\ v_4(x) &= (15/32)(3 - 10x^2 + 7x^4)g(x); \\ v_6(x) &= (105/256)(5 - 35x^2 + 63x^4 - 33x^6)g(x); \\ v_8(x) &= (315/4096)(35 - 420x^2 + 1386x^4 - 1716x^6 + 715x^8)g(x); \\ v_{10}(x) &= (3465/65536)(63 - 1155x^2 + 6006x^4 - 12870x^6 + 12155x^8 - \\ &\quad - 4199x^{10})g(x), \end{aligned}$$

где  $g(x) = I_{(-1,1)}(x)$  — индикатор интервала  $(-1, 1)$ .

Метод перекрестной проверки, описанный ниже, позволяет улучшить выбор параметров  $u(x)$ ,  $v(x)$ ,  $a$  и  $b$  оценки (2), а заодно и уточнить наши априорные предположения относительно степени гладкости функций  $p(x)$  и  $\gamma(x)$ . Пусть  $\lambda_{n-1}^{(k)}(x)$  — оценка вида (2), построенная по

выборке  $\{(\xi_i, \eta_i), i = \overline{1, n}, i \neq k\}$ , и

$$\Delta_n = \Delta_n(u, v, a, b) = \sum_{k=1}^n [\lambda_{n-1}^{(k)}(\xi_k) - \eta_k]^2 \alpha(\xi_k),$$

где  $\alpha(x)$  — некоторая неотрицательная весовая функция, выбираемая исследователем в соответствии с целями и задачами данного эксперимента.

В отличие от работ [1, 2], в которых для случая

$$v(x) = u(x) \text{ и } b = a = h \quad (4)$$

предлагается искать минимум величины  $\Delta_n$  лишь по параметру  $h$  и объявить соответствующее этому минимуму значение  $h$  оптимальным, здесь рекомендуем искать минимум величины  $\Delta_n$  в гораздо более широкой области значений функциональных параметров  $u(x)$  и  $v(x)$  и масштабных множителей  $a$  и  $b$ . А именно: вместо соотношений (4) предполагаем лишь, что выполняются условия (3). Наилучшим для данного эксперимента будем считать тот выбор параметров  $u(x)$ ,  $v(x)$ ,  $a$  и  $b$ , удовлетворяющих условиям (3), при котором величина  $\Delta_n$  обращается в минимум.

В ряде случаев принятые нами зависимости (3) относительно параметров  $u(x)$ ,  $v(x)$ ,  $a$  и  $b$  могут быть еще более ослаблены. Предположим, например, что: а) весовая функция  $\alpha(x)$  положительна лишь на некотором множестве  $A$ , на котором  $p(x) > c > 0$ , и б) объем выборки  $n$  не слишком мал. В этом случае условия (3) могут быть опущены. В силу предположения «а» и равномерной (с вероятностью 1) сходимости оценки  $p_n(x)$  к плотности вероятности  $p(x)$  (см., например, [7—9]) при достаточно больших  $n$  оценка  $p_n(x)$  будет с вероятностью 1 положительной для всех  $x \in A$  даже в случае применения знакопеременного ядра  $u(x)$ .

Разумеется, расширение области допустимых значений параметров  $u(x)$ ,  $v(x)$ ,  $a$  и  $b$  не является самоцелью. Оно позволяет нам, используя метод перекрестной проверки, улучшить качество статистического оценивания кривой регрессии  $\lambda(x)$ .

#### ЛИТЕРАТУРА

1. Hall P. Asymptotic properties of integrated square error and cross-validation for kernel estimation of a regression function // Zeitschr. für Wahrscheinlichkeitstheorie und verw. Gebiete.— 1984.— Bd 67, N 2.— S. 175.
2. Collomb G., Sarda P., Vieu P. Weak pointwise consistency of the cross validatory window estimate in nonparametric regression estimation // Commentationes Mathematicae Universitatis Carolinae.— 1985.— V. 26, N 4.— P. 789.
3. Алексеев В. Г. О непараметрических оценках плотности вероятности и ее производных // ППИ.— 1982.— Т. 18, № 2.
4. Alekseev V. G. On the use of alternating kernels in nonparametric statistical estimation // Lecture Notes in Mathematics.— Berlin; Heidelberg; New York; Tokyo: Springer-Verlag, 1983.— V. 1021.
5. Алексеев В. Г. Некоторые практические рекомендации по спектральному анализу гауссовых стационарных случайных процессов // ППИ.— 1973.— Т. 9, № 4.
6. Алексеев В. Г. О вычислении спектров стационарных случайных процессов по выборкам большого объема // ППИ.— 1980.— Т. 16, № 1.
7. Алексеев В. Г. Об оценке плотности вероятности и ее производных // Мат. заметки.— 1972.— Т. 12, № 5.
8. Коцаков В. Д. Теорема об уклонении эмпирической меры и ее приложения // Теория вероятностей и ее применения.— 1984.— Т. 29, № 1.
9. Singh R. S. Improvement on some known nonparametric uniformly consistent estimators of derivatives of a density // Ann. Statist.— 1977.— V. 5, N 2.— P. 394.

Поступила в редакцию 2 апреля 1987 г.