

РОССИЙСКАЯ АКАДЕМИЯ НАУК

СИБИРСКОЕ ОТДЕЛЕНИЕ

А В Т О М Е Т Р И Я

---

№ 6

1999

УДК 681.513

И. А. Пестунов

(Красноярск)

БЫСТРЫЕ НЕПАРАМЕТРИЧЕСКИЕ  
АЛГОРИТМЫ КЛАССИФИКАЦИИ  
ДЛЯ ОБРАБОТКИ БОЛЬШИХ МАССИВОВ ДАННЫХ

Предлагается простой метод построения непараметрических алгоритмов классификации, быстродействие которых в среднем в десять и более раз превышает быстродействие классификаторов Розенблатта – Парзена, и при этом они лишь незначительно уступают последним по качеству классификации. Приводятся результаты статистического моделирования, подтверждающие эффективность предлагаемого метода.

**Введение.** В последнее десятилетие значительно возрос интерес к непараметрическим алгоритмам классификации [1–4]. Это связано с тем, что указанные алгоритмы не требуют «жестких» ограничений на вид условных плотностей распределения (унимодальности, нормальности и т. п.) и обеспечивают высокую достоверность распознавания. Однако применение известных (подстановочных) непараметрических алгоритмов классификации при обработке больших массивов данных (например, полученных с помощью датчиков дистанционного зондирования земной поверхности) приводит к неприемлемо большим вычислительным затратам [5]. Поэтому актуальной задачей является разработка вычислительно-эффективных непараметрических алгоритмов распознавания образов.

В настоящей работе представлен простой метод генерации быстрых непараметрических алгоритмов классификации, который основан на сокращении числа представителей обучающей выборки, непосредственно используемых при формировании классификаторов Розенблатта – Парзена.

**Метод генерации быстрых непараметрических алгоритмов классификации.** Пусть в  $X \subseteq \Re^k$  с известными и отличными от нуля вероятностями  $q_1, \dots, q_M$  ( $\sum_{i=1}^M q_i = 1$ ) регистрируются наблюдения из классов  $\Omega_1, \dots, \Omega_M$

соответственно. Наблюдение из  $\Omega_i$  есть реализация  $k$ -мерного случайного вектора-столбца  $x^{(i)} = (x_1^{(i)}, \dots, x_k^{(i)})^T \in \Re^k$ , плотность распределения которого  $f_i(x)$  не известна ( $i = 1, M$ ), но имеется классифицированная обучающая выборка  $V = \bigcup_{i=1}^M V^{(i)}$  объемом  $N = \sum_{i=1}^M N_i$ , где  $V^{(i)} = \{x_j^{(i)} : x_j^{(i)} \in \Re^k, j = 1, N_i\}$  – множество из  $N_i$  независимых наблюдений класса  $\Omega_i$ . Тогда общий вид ре-

шающего правила (РП) из семейства непараметрических классификаторов Розенблатта – Парзена можно описать формулой

$$\delta_0 = \delta_0(x; V) = \arg \max_{i \in S} \{q_i \hat{f}_{N_i}^{(i)}(x)\}.$$

Здесь  $S = \{1, 2, \dots, M\}$ ;  $\hat{f}_{N_i}^{(i)}(x)$  – непараметрическая оценка плотности  $f_i(x)$  в точке  $x \in X$ , определяемая выражением

$$\hat{f}_{N_i}^{(i)}(x) = \frac{1}{N_i} \sum_{j=1}^{N_i} h^{-k} \Phi \left[ \frac{x_1 - x_{j1}^{(i)}}{h}, \dots, \frac{x_k - x_{jk}^{(i)}}{h} \right],$$

где  $\Phi(\cdot)$  – некоторая заданная колоколообразная функция (ядро);  $h$  – параметр сглаживания [6].

Вероятность ошибки классификации для РП  $\delta_0$  определяется выражением

$$P_N = P_N(\delta_0; V) = \sum_{i=1}^M q_i \int_{R^k} \chi_{\hat{X}_i}(x) f_i(x) dx,$$

где  $\{\hat{X}_i\}$  – разбиение пространства  $X$ , соответствующее РП  $\delta_0$ ;  $\chi_{\hat{X}_i}(\cdot)$  – индикаторная функция  $\hat{X}_i$ .

Обратим внимание, что для классификации с помощью правила  $\delta_0$  некоторой точки  $x \in X$  не требуется знать значения оценок  $\{\hat{f}_{N_i}^{(i)}(x)\}$  как таковых, а достаточно лишь решить вопрос о том, какая из величин  $q_1 \hat{f}_{N_1}^{(1)}(x), \dots, q_M \hat{f}_{N_M}^{(M)}(x)$  больше. На этом основании предлагается в выражении для  $\delta_0$  оценки  $\{\hat{f}_{N_i}^{(i)}(x)\}$  заменить более простыми (в смысле объема вычислений) статистиками  $\{\tilde{f}_{N_i}^{(i)}(x)\}$ . Здесь

$$\tilde{f}_{N_i}^{(i)}(x) = \frac{1}{N_i} \sum_{j=1}^{N'_i} h^{-k} \Phi \left[ \frac{x_1 - x_{\alpha_i(j),1}^{(i)}}{h}, \dots, \frac{x_k - x_{\alpha_i(j),k}^{(i)}}{h} \right],$$

где  $\alpha_i(j) \in \{1, 2, \dots, N_i\}$ , причем для всех  $p \neq q$   $\alpha_i(p) \neq \alpha_i(q)$ ;  $N'_i < N_i$ .

В результате такой замены РП  $\delta_0$  преобразуется в решающее правило

$$\delta_1 = \delta_1(x; W) = \arg \max_{i \in S} q_i \tilde{f}_{N_i}^{(i)}(x).$$

Здесь  $W = \bigcup_{i=1}^M W^{(i)}$  есть выборка (назовем ее рабочей) объемом  $N' = \sum_{i=1}^M N'_i$ , где  $W^{(i)} = \{x_{\alpha_i(j)}^{(i)} \in V^{(i)}, j = 1, 2, \dots, N'_i\}$ .

Рабочую выборку  $W$  будем формировать из условия сохранения значения оценки вероятности ошибки классификации  $P_N$ , полученной методом переклассификации, так как в этом случае гарантируется состоятельность правила  $\delta_1$ .

**Процедура генерации рабочей выборки.** Для формирования рабочей выборки  $W$  могут быть предложены различные процедуры. Опишем подробно одну из них для двухальтернативного случая.

Обозначим  $z_1 = x_1^{(1)}, \dots, z_{N_1} = x_{N_1}^{(1)}, z_{N_1+1} = x_1^{(2)}, \dots, z_N = x_{N_2}^{(2)}$ . Тогда предлагаемую процедуру можно записать в виде последовательности шагов.

**Шаг 1.** Классифицировать элементы множества  $Z = \{z_i, i=1, N\}$  с помощью РП  $\delta_0$ . Результаты классификации занести в одномерный массив  $D$  размерностью  $N$  по следующему правилу:  $D[i]=1$ , если  $z_i$  относится к первому классу,  $D[i]=2$  в противном случае.

**Шаг 2.** В рабочую выборку  $W$  включить точки  $z_1$  и  $z_{N_1+1}$ . Из оставшихся точек множества  $Z$  сформировать две контрольные выборки  $Z1 = \{z_2, z_3, \dots, z_{N_1}\}$  и  $Z2 = \{z_{N_1+2}, z_{N_1+3}, \dots, z_N\}$ . Установить  $N' = 2, N'' = 2, p = 0$  и перейти к шагу 5.

**Шаг 3.** Если  $N' = N''$ , то процедуру закончить, иначе установить  $p = 0, N'' = N'$  и перейти к шагу 5.

**Шаг 4.** Если  $p = N$ , то перейти к шагу 3.

**Шаг 5.** Положить  $p := p + 1$  и классифицировать точку  $z_p$  в соответствии с РП  $\delta_1$ . Если в результате классификации  $z_p$  попадет в первый класс, то перейти к шагу 8.

**Шаг 6.** Если  $D[p] = 2$ , то перейти к шагу 4.

**Шаг 7.** Среди элементов выборки  $Z1$  найти точку, ближайшую к  $z_p$ , и включить ее в выборку  $W$ , исключив при этом из  $Z1$ . Положить  $N' := N' + 1$  и классифицировать точку  $z_p$  в соответствии с РП  $\delta_1$ . Если в результате классификации  $z_p$  попадет в первый класс, то перейти к шагу 4, иначе – к началу данного шага.

**Шаг 8.** Если  $D[p] = 1$ , то перейти к шагу 4.

**Шаг 9.** Среди точек выборки  $Z2$  найти точку, ближайшую к  $z_p$ , и включить ее в выборку  $W$ , одновременно исключив из  $Z2$ . Затем, положив  $N' := N' + 1$ , классифицировать точку  $z_p$  в соответствии с РП  $\delta_1$ . Если в результате классификации  $z_p$  попадет в первый класс, то перейти к началу данного шага, иначе – к шагу 4.

На основе этой процедуры легко построить процедуру формирования выборки  $W$  для случая  $M > 2$  классов.

**Результаты статистического моделирования.** Изложенная выше процедура исследовалась на большом количестве как модельных, так и реальных данных. Приведем типичные результаты одного из экспериментов. Рассматривался случай трех равновероятных классов в двумерном признаковом пространстве. Первый класс описывался нормальной плотностью с вектором математического ожидания  $\mu^{(1)} = (0, 0)^T$  и ковариационной матрицей

$$\Sigma_1 = \begin{pmatrix} \sigma^2 & 0 \\ 0 & \sigma^2 \end{pmatrix},$$

где параметр  $\sigma^2$  принимал два значения:  $\sigma^2 = 1,7$  и  $\sigma^2 = 3,2$ .

Для объектов второго класса значения первого признака были распределены равномерно на отрезке  $[-4, 6]$ , а значения второго признака определялись

в соответствии с выражением  $x = -\sqrt{25 - (y-1)^2} + \xi$ , где  $y$  и  $x$  есть значения первого и второго признаков соответственно;  $\xi$  – случайная величина, имеющая равномерное распределение на отрезке  $[-1,5, 1,5]$ . Третий класс генерировался путем зеркального отражения в плоскости  $XY$  точек второго класса относительно начала координат. Байесовская вероятность ошибки составляла  $\sim 0,03$  для  $\sigma^2 = 1,7$  и  $\sim 0,07$  для  $\sigma^2 = 3,2$ .

Таблица 1

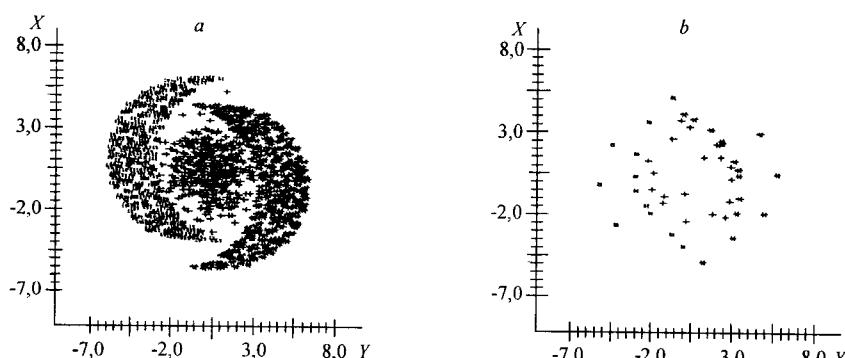
$\sigma^2$	$N = N_1 + N_2 + N_3$			
	150	300	600	1500
1,7	22 4	29 6	41 10	59 15
3,2	27 5	39 6	59 17	112 25

Для данной модели генерировалось по 20 независимых выборок объемом  $N = 150, 300, 600$  и  $1500$  ( $N_1 = N_2 = N_3$ ). Затем строилось РП  $\delta_0$  (использовалось нормальное ядро) и для каждой из выборок с помощью метода «скользящего экзамена» определялся наиболее подходящий параметр  $h$ . После этого выполнялась процедура генерации рабочих выборок. Полученные результаты представлены в табл. 1 (в каждой ячейке указывается средний объем рабочих выборок (числа выделены) и среднеквадратическое отклонение).

В качестве дополнения к численным результатам на рисунке в графическом виде представлены исходная ( $N_1 = N_2 = N_3 = 500$ ) и рабочая ( $N'_1 = 12$ ,  $N'_2 = 15$ ,  $N'_3 = 19$ ) выборки (для повышения наглядности восприятия обучающих выборок начала координат смещены в отрицательную область).

С целью выяснения вопроса об эффективности предлагаемого метода с точки зрения достоверности распознавания получаемого РП  $\delta_1$  было проведено экспериментальное сравнение решающих правил  $\delta_0$  и  $\delta_1$ .

Для данных, относящихся к описанной выше модели, для каждого случая генерировалось по  $n = 20$  независимых обучающих выборок объемом  $N = 150, 300, 600, 1500$  и по 20 контрольных выборок объемом 1500 (по 500 точек на класс). Затем для полученных обучающих выборок строились РП  $\delta_0$  и РП  $\delta_1$ . Далее для каждой группы из  $n = 20$  выборок оценивалось математическое ожидание вероятности ошибки классификации  $P_N$  и ее среднеквадратическое отклонение  $\hat{\sigma}(P_N)$ . Результаты этих вычислений приведены в табл. 2 (значения  $P_N$  выделены).



Исходная (a) и рабочая (b) выборки

Таблица 2

$\sigma^2$	РП	$N = N_1 + N_2 + N_3$			
		150	300	600	1500
1,7	$\delta_0$	<b>0,04</b> 0,015	<b>0,031</b> 0,008	<b>0,030</b> 0,006	<b>0,029</b> 0,005
	$\delta_1$	<b>0,062</b> 0,020	<b>0,044</b> 0,012	<b>0,036</b> 0,006	<b>0,030</b> 0,005
3,2	$\delta_0$	<b>0,104</b> 0,022	<b>0,090</b> 0,013	<b>0,083</b> 0,006	<b>0,077</b> 0,005
	$\delta_1$	<b>0,124</b> 0,022	<b>0,099</b> 0,016	<b>0,086</b> 0,008	<b>0,077</b> 0,005

**Заключение.** В данной работе указано на принципиальное отличие задачи оценивания плотности распределения при построении правила классификации от задачи оценивания плотности, рассматриваемой независимо. На основе использования этого факта предложен простой метод генерации вычислительно-эффективных непараметрических алгоритмов классификации для обработки больших массивов данных. Предложенный метод позволяет достичь разумного компромисса между скоростью обработки и достоверностью распознавания.

#### СПИСОК ЛИТЕРАТУРЫ

- Горбачев О. Г., Гребенщиков А. Ю. Быстрые алгоритмы принятия решения по многомерным данным, использующие обучающие выборки ограниченного объема // Изв. АН СССР. Техн. кибернетика. 1991. № 4. С. 91.
- Arinstrong M. L., Abdou I. E. Nonparametric models and crop classification // Int. Geosci. and Remote Sens. Symp. (IGARSS'85). N. Y. 1985. V. 2. P. 892.
- Fukunaga K., Hayes R. R. The reduced Parzen classifier // IEEE Trans. Pattern Analysis and Machine Intelligence. 1989. 11, N 4. P. 423.
- Харин Ю. С. Робастность в статистическом распознавании образов. Минск: Университетское изд-во, 1992.
- Абрамович Н. С., Ковалев А. А., Плюта В. Е. К вопросу о классификации природных образований по их оптическим характеристикам в условиях малых выборок // Исследование Земли из космоса. 1985. № 4. С. 105.
- Шапиро Е. И. Непараметрические оценки плотности вероятности в задачах обработки результатов наблюдений // Зарубеж. радиоэлектрон. 1976. № 2. С. 3.

Поступила в редакцию 16 февраля 1999 г.