

РОССИЙСКАЯ АКАДЕМИЯ НАУК  
СИБИРСКОЕ ОТДЕЛЕНИЕ

А В Т О М Е Т Р И Я

---

№ 6

1999

УДК 681.513

А. В. Лапко, В. А. Лапко, С. В. Ченцов

(Красноярск)

НЕПАРАМЕТРИЧЕСКИЕ МОДЕЛИ РАСПОЗНАВАНИЯ ОБРАЗОВ  
В УСЛОВИЯХ МАЛЫХ ВЫБОРОК\*

С позиций принципов имитации систем и последовательных процедур принятия решений рассматриваются направления решения проблем анализа малых выборок. Предлагаются оригинальные непараметрические методы классификации статистических данных, модели стохастических зависимостей и самообучающиеся алгоритмы оптимизации статистических объектов, развивающие теорию непараметрических обучающихся систем.

**Введение.** Внимание исследователя всегда привлекали методы обработки данных, ориентированные на достаточно низкий уровень априорной информации, что объясняется не только распространностью в практике подобных условий, но и возможностью построения универсальных алгоритмов, не зависящих от природы анализируемых объектов. Указанные особенности свойственны непараметрическим моделям и алгоритмам. Их применение не требует введения системы предположений для подгонки объективной реальности под узкие рамки конкретного метода. Основываясь в значительной степени на обучающихся выборках, можно получить результаты, максимально адекватные действительности.

Актуальным направлением развития теории непараметрической статистики является разработка методов принятия решений в условиях малых выборок.

В данном случае применение традиционных подходов не обосновано. Для решения проблемы анализа малых выборок предлагается, используя принципы имитации систем и последовательные процедуры принятия решений, искусственно увеличить объем исходных данных либо отношение объем выборки/размерность, что позволяет воспользоваться хорошо разработанным аппаратом непараметрической статистики.

С этих позиций синтезированы непараметрические модели распознавания образов и нестационарных временных зависимостей, рассмотрены задачи оптимизации и идентификации систем в условиях малых выборок.

1. **Непараметрическая оценка плотности вероятности в условиях малых выборок.** Для решения проблемы малых выборок при оценении плотностей вероятности  $p(x)$  увеличим объем исходных данных  $x^i$ ,  $i=1, n$ , за счет результатов статистического моделирования. С этой целью в  $\beta$ -окре-

---

\* Работа выполнена при поддержке Российского фонда фундаментальных исследований (грант № 97-01-01043).

стности каждой  $i$ -й точки выборки осуществим  $m$  имитаций с законом распределения  $p_2(x_2)$ . Полученная статистическая выборка  $x^i + x_2^j$ ,  $j=1, m$ ,  $i=\overline{1, n}$ , при равновероятных значениях  $x^i$ ,  $i=\overline{1, n}$ , соответствует смеси плотностей вероятности

$$\hat{p}(x) = \frac{1}{n} \sum_{i=1}^n p_2^i(x_2). \quad (1)$$

Нетрудно заметить, что непараметрическая оценка (1) имеет вид

$$\tilde{\hat{p}}(x) = (nm)^{-1} \sum_{i=1}^n \sum_{j=1}^m \Phi\left(\frac{x - x' - x_2^j}{c}\right), \quad (2)$$

где  $\Phi(\cdot) \in H$  – положительные, нормированные и симметричные ядерные функции;  $c = c(n)$  – последовательность положительных чисел (коэффициентов размытия) [1].

Рассмотрим асимптотические свойства статистики (2). Введем обозначения:  $\bar{x}^\nu = \int x^\nu p(x) d(x)$ ,  $\bar{x}_2^\nu = \int x_2^\nu p_2(x_2) dx_2$ ,  $\nu = \overline{1, 4}$ , где  $\nu$  – показатель степени.

Предположим, что  $p(x)$  ограничена и непрерывна со всеми своими производными до порядка  $k$  включительно на  $\Omega(x)$ , причем  $\|p^{(k)}(x)\| < \infty \forall x \in \Omega(x)$ . Эти условия, налагаемые на  $p(x)$ , обозначим через  $G_k$ . Тогда справедлива следующая

**Теорема 1.** Пусть 1)  $p(x)$  и  $p_2(x_2)$  удовлетворяют условиям  $G_2$ , причем  $p_2(x_2)$  является симметричной функцией,  $\Phi(u) \in H$ ; 2) последовательности  $c > 0$ ,  $\beta > 0$ ,  $\beta > c$  такие, что при  $n \rightarrow \infty$ ,  $m \rightarrow \infty$  значения  $c \rightarrow 0$ ,  $\beta \rightarrow 0$ , а  $\bar{x}_2^2 (nm)^{-1} \rightarrow 0$ .

Тогда смещение

$$\mu\{\tilde{\hat{p}}(x) - p(x)\} \approx \frac{p^{(2)}(x)}{2} (c + \bar{x}_2^2),$$

квадратическое отклонение

$$\begin{aligned} \mu\{(\tilde{\hat{p}}(x) - p(x))^2\} &\approx \frac{p^{(2)}(x) \|\Phi(u)\|^2}{2nm} \bar{x}_2^2 + \frac{1}{n} \left[ p_2^2(x_2) - 2p_2(x_2)p_2^{(1)}(x_2)\bar{x}_2 + \right. \\ &+ ((p_2^{(1)}(x_2))^2 + p_2(x_2)p_2^{(2)}(x_2))\bar{x}_2^2 - p_2^{(1)}(x_2)p_2^{(2)}(x_2)\bar{x}_2^3 + \frac{(p_2^{(2)}(x))^2}{4} \bar{x}_2^4 \left. \right] + \\ &+ \frac{1}{m} \left[ p^2(x) + (p^{(1)}(x))^2 \bar{x}_2^2 + \frac{(p^{(2)}(x))^2}{4} \bar{x}_2^4 + p(x)p^{(2)}(x)\bar{x}_2^2 \right] + \\ &+ \frac{(p^{(2)}(x))^2}{4} (c^2 + \bar{x}_2^2)^2. \end{aligned}$$

Отметим естественную зависимость асимптотических свойств  $\tilde{p}(x)$  от объема исходной информации и результатов статистического моделирования. Причем условия конечных  $n$  и  $m \rightarrow \infty$  не обеспечивают сходимость  $\tilde{p}(x)$  к  $p(x)$ .

Учитывая, что непараметрические алгоритмы распознавания образов являются статистическими оценками линейных функционалов от плотности вероятности, появляется возможность их синтеза и анализа на основе предложенной статистики (2).

Разработанная непараметрическая оценка плотности вероятности имеет самостоятельное значение в имитационном моделировании. Доказательство теоремы обосновывает методику продолжения случайных последовательностей в соответствии с правилом синтеза оценки плотности вероятности.

**2. Многоуровневые системы распознавания образов.** Основным показателем малых выборок служит низкий уровень отношения объем выборки/размерность пространства признаков ( $n/k$ ). Для обеспечения приемлемого отношения ( $n/k$ ) предлагается условно-последовательная процедура принятия решений. Исходная задача распознавания образов (РО) разбивается на  $T$  взаимосвязанных задач РО  $m(x) = \{m_t(x(t)), t=1, T\}$  по ограниченным наборам признаков сигнала  $x = (x(t), t=1, T)$ .

Решающее правило на каждом последующем этапе формируется в пространстве признаков  $x(t+1)$  по данным ошибочных ситуаций предыдущего этапа:

$$m_t(x(t)) : \begin{cases} x \in \Omega_j(x), \text{ если } f_{jj}(x(t)) < 0 \text{ и } p_j(x(t)) = 0, \\ \text{использовать } m_{t+1}(x(t+1)), \text{ если } x(t) \in \Omega_{jj}(x(t)). \end{cases}$$

Здесь алгоритм  $m_{t+1}(x(t+1))$  осуществляет классификацию в пространстве признаков  $x(t+1)$  при условии принадлежности  $x(t)$  области пересечения классов  $\Omega_{jj}(x(t)) = \Omega_j(x(t)) \cap \Omega_{jj}(x(t))$ ;  $f_{jj}(\cdot)$  – уравнение разделяющей поверхности между  $j$ -м классом и областью  $\Omega_j(x(t))$ .

Очевидно, что на первых этапах последовательностью алгоритмов  $\{m_t(x(t)), t=1, T-1\}$  решения принимаются однозначно, а ошибка распознавания образов формируется на заключительном этапе.

Использование иерархических структур в процессах классификации создает предпосылки рационального учета дополнительной информации о ранее вскрытых закономерностях в пространстве признаков сигнала  $x(t)$ ,  $t=1, T$ , и позволяет существенно снизить время  $q_n$  решения задачи классификации по сравнению со временем  $q$  прямой обработки сигнала  $x$ . Показано, что

$$q_n/q = \sum_{t=1}^T k(t) P\{x(t) \in \overline{\Omega}_{jj}(\bar{x}(t))\}/k < 1, \quad x(t) = (x_v(t), v=1, \overline{k(t)}), \quad k = \sum_{t=1}^T k(t),$$

и при равных размерностях  $k(t) = k/T$  наборов признаков  $x(t)$  сигнала  $x$  не превышает величины

$$(1 - P^T(1))/[T(1 - P(1))], \quad P(1) = P\{x(1) \in \Omega_{jj}(x(1))\}.$$

Для обеспечения минимального среднего времени классификации необходимо на первых этапах обработки данных располагать наборы признаков с меньшими значениями ошибки распознавания образов.

Формирование информативных наборов признаков осуществляется с помощью оригинального метода минимизации описания.

Пусть выбрано семейство решающих правил при заданном алфавите классов и проведен вычислительный эксперимент, в результате которого получены последовательности  $(\bar{\rho}_v, v=1, k, v \neq t), (\bar{\rho}_{v,t}, v, t=1, k)$  значений оценок ошибки распознавания образов в пространстве только одного признака  $x_v, v=1, k$ , сигнала и их парных сочетаний  $(x_v, x_t), v, t=1, k, t \neq v$ . Данный этап будем называть обучением минимизации описания, так как полученная при этом информация оказывается достаточной для целенаправленного формирования наборов признаков более чем два.

Построим граф  $\Gamma(X, R)$  взаимосвязи между признаками сигнала, где  $X = (x_v, v=1, k); R = \{r_{vt}\}$  – множество ребер графа. Между двумя вершинами  $(x_v, x_t)$  существует ребро, т. е.  $r_{vt} \in R$ , если значение  $\bar{\rho}_{vt}$  и произведение  $\bar{\rho}_v \bar{\rho}_t$  достоверно (с некоторым уровнем доверия  $\beta$ ) не отличаются. Из определения ошибки распознавания образов следует, что это возможно лишь в случае, если признаки  $(x_v, x_t)$  сигнала статистически независимы.

Применяя методы аппарата теории графов, проведем декомпозицию  $\Gamma(X, R)$  на подграфы  $\Gamma_j(X_j, R_j)$ , которые обладают свойством сильной связности и не содержатся в других подграфах с таким же свойством. Множество  $X_j \subset X$  составляют вершины исходного графа, которые попарно взаимодостижимы длиной пути, равной единице, т. е. между любыми двумя вершинами  $(x_v, x_t)$  существует ребро. Но тогда признаки из набора  $x(j)$ , соответствующего множеству вершин  $X_j$  подграфа  $\Gamma_j(X_j, R_j)$ , являются статистически независимыми, а ошибка распознавания образов на их основе пересчитывается по формуле

$$\rho(x(j)) = \prod_{v \in I_j} \bar{\rho}_v, \quad x(j) = (x_v, v \in I_j),$$

где  $I_j$  – множество номеров признаков, входящих в набор  $x(j)$ . С другой стороны, исходя из методики построения графа  $\Gamma(X, R)$ , наборы признаков  $x(j), j=1, T$ , статистически взаимосвязаны в процессе решения задачи распознавания образов. Поэтому они в значительной мере содержат одинаковый объем «полезной» информации о задаче классификации сигналов.

С этих позиций  $x(j), j=1, T$ , представляют собой варианты наборов информативных признаков, наилучший  $x(j^*)$  из которых определяется условием

$$\bar{\rho}(x(j^*)) = \min_j \bar{\rho}(x(j)), \quad j = 1, T. \quad (3)$$

Если размерность вектора  $x(j)$  значительна и не устраивает исследователя, то проводятся дополнительная декомпозиция подграфов  $\Gamma_j(X_j, R_j), j=1, T$ , и анализ элементов полученной структуры в процессе решения задачи (3).

**3. Непараметрические алгоритмы автоматической классификации.** Определим точки исходной выборки  $V$  как статистические оценки центров «блуждания» унимодальных классов, количество  $M$  которых неизвестно.

Построим для каждой точки  $V$  доверительный интервал с уровнем доверия  $h$ . Пусть  $V$  – однородная выборка, т. е.  $M = 1$ . Тогда существует такой  $h$ , когда вероятность принадлежности точек  $V$  максимальной области взаимного пересечения доверительных интервалов равна либо превышает  $1 - h$ . Если  $V$  неоднородная выборка ( $M > 1$ ), то ее классификация осуществляется путем решения последовательности задач проверки статистических гипотез однородности исходной либо промежуточных выборок, получаемых в процессе декомпозиции  $V$ . Предложенный подход допускает обобщение на случай разнотипных данных [2].

**4. Непараметрические модели распознавания образов на основе метода коллективного оценивания.** Принципы коллективного оценивания нашли широкое распространение на завершающем этапе формирования теории адаптивных систем, когда возникла необходимость обобщения либо получения интегрированных знаний в задачах исследования систем.

В предлагаемом подходе составляющие коллектива представляют собой упрощенные варианты решающих правил, количество которых соизмеримо с объемом обучающей выборки. Следует ожидать, что подобные алгоритмы принятия решений адекватны уровню априорной неопределенности, соответствующему локальным аппроксимациям, и обобщают последние.

*Метод коллективного оценивания.* Пусть задана выборка  $V = (x^i, y^i, i = \overline{1, N})$  из статистически независимых наблюдений неизвестной зависимости

$$y = f(x) \forall x \in R^k. \quad (4)$$

Поставим в соответствие ряду точек обучающей выборки  $(x^i, y^i)$  некоторую аппроксимацию  $\phi_i(x, \alpha')$  зависимости (4), параметры которой удовлетворяют условиям

$$\begin{aligned} y^i &= \phi_i(x^i, \bar{\alpha}^i), \\ \bar{\alpha}^i &= \arg \min_{n-1} \sum_{\substack{j=1 \\ j \neq i}}^N (y^j - \phi_j(x^j, \alpha))^2, \quad i = \overline{1, n}, \quad n \ll N. \end{aligned} \quad (5)$$

Тогда непараметрический коллектив представляется в виде

$$\bar{y} = \bar{f}(x) = \sum_{i=1}^n \phi_i(x, \bar{\alpha}^i) \lambda^i(x), \quad (6)$$

где положительная, ограниченная значением единицы функция  $\lambda^i(x)$  определяет «вес» правила  $\phi_i(x, \alpha')$  при формировании решения в ситуации  $x$ .

Пример функции  $\lambda^i(x)$  – нормированное расстояние между точками  $(x, x^i)$  либо «весовая» функция

$$\lambda^i(x) = \frac{\prod_{v=1}^k \Phi\left(\frac{x_v - x_v^i}{c_v}\right)}{\sum_{j=1}^n \prod_{v=1}^k \Phi\left(\frac{x_v - x_v^j}{c_v}\right)}, \quad (7)$$

составленная из «ядерных» функций  $c_v^{-1}\Phi\left(\frac{x_v - x_v^i}{c_v}\right)$ .

*Алгоритмы распознавания образов.* Пусть  $V = (x^i, \sigma(x^i), i=1, \overline{N})$  – обучающая выборка, составленная из параметров складывающейся ситуации  $x^i$  и соответствующих им «указаний учителя»  $\sigma(x^i)$  о принадлежности  $i$ -й ситуации к одному, например, из двух классов.

Следуя методике синтеза коллективов решающих правил, для каждой опорной точки построим линейное уравнение разделяющей поверхности  $\phi_{12}^i(x, \bar{\alpha}^i)$  между классами. Тогда решающее правило, построенное на ее основе, имеет вид

$$m^i(x) : \begin{cases} x \in \Omega_1, & \text{если } \phi_{12}^i(x, \bar{\alpha}^i) \leq 0, \\ x \in \Omega_2, & \text{если } \phi_{12}^i(x, \bar{\alpha}^i) > 0. \end{cases}$$

Параметры  $i$ -й решающей функции находятся из условия минимума эмпирической ошибки распознавания образов.

С этих позиций непараметрический коллектив уравнений разделяющих поверхностей в двухальтернативной задаче распознавания образов записывается как

$$\tilde{f}_{12}(x) = \left( n \prod_{v=1}^k c_v \right)^{-1} \sum_{i=1}^n \phi_{12}^i(x, \bar{\alpha}^i) \prod_{v=1}^k \Phi\left(\frac{x_v - x_v^i}{c_v}\right).$$

Отличие от традиционной непараметрической байесовской оценки разделяющей поверхности заключается в замене «указаний учителя»

$$\delta(x^i) = \begin{cases} -1, & \text{если } x \in \Omega_1, \\ +1, & \text{если } x \in \Omega_2, \end{cases}$$

на упрощенные решающие функции  $\phi_{12}^i(x, \bar{\alpha}^i)$ ,  $i=1, \overline{n}$ .

Обобщенное решение формируется с учетом знака функции  $\tilde{f}_{12}(x)$ .

Статистика  $\tilde{f}_{12}(x)$  может быть представлена в виде непараметрической оценки уравнения разделяющей поверхности и слагаемого, которое стремится к нулю с ростом  $n$ . При этом вид упрощенных решающих функций оказывает несущественное влияние на качество распознавания образов.

**5. Самообучающийся алгоритм поиска глобального экстремума.** Поиск глобального экстремума является классической проблемой математической кибернетики, имеющей важное прикладное значение в задачах управления. Сложность ее решения возрастает при неполной информации о виде целевой функции  $y = \varphi(x, u)$ , представляющей часто с помощью статистической выборки наблюдений  $V = (x^i, u^i, y^i, i=1, \overline{n})$ .

В этих условиях для поиска относительного экстремума  $\varphi(x, u)$  по  $u$  при фиксированном  $x$  применяются непараметрические алгоритмы оптимизации, основанные на итерационной процедуре статистического оценивания условного математического ожидания  $M(y/x, u)$ . Предлагаемые алгоритмы используют случайную стратегию выбора начальных точек  $u$  и процедуры оптимизации и специальную организацию поисковых шагов, что не гарантиру-

ет нахождения относительного глобального экстремума и требует значительных вычислительных затрат.

Рассмотрим принципиально новые самообучающиеся непараметрические методы поиска относительного глобального экстремума, основанные на декомпозиции исходной задачи с помощью алгоритмов классификации, с последующим решением задач локальной оптимизации и сравнением их результатов.

В предлагаемом подходе непосредственной оптимизации предшествует этап системного анализа статистической выборки  $V$  с целью выделения множеств точек  $V_t$ , соответствующих областям  $\Omega_t(x, u)$ ,  $t = \overline{1, M}$ ,  $t$ -го максимума критерия  $y = \phi(x, u)$ . Тем самым может быть осуществлена кусочная аппроксимация критерия

$$y = \phi(x, u) = \phi_t(x, u) \quad \forall (x, u) \in \Omega_t, \quad t = \overline{1, M},$$

по выборкам  $V_t$ ,  $t = \overline{1, M}$ .

Для реализации данного этапа построим статистическую оценку плотности вероятности  $\bar{p}_\phi(x, u)$ , вид которой с точностью до константы не отличается от целевой функции  $\phi(x, u)$ . Синтез  $\bar{p}_\phi(x, u)$  возможен, например, при равномерном законе распределения  $(x, u)$  по выборке

$$\left( x^i, u^i, y^i / \sum_{j=1}^n y^j, i = \overline{1, n} \right)$$

с помощью оценки плотности вероятности регрессионного типа [3]. Далее по оценке  $\bar{p}_\phi(x, u)$  построим датчик случайной величины  $(x, u)$  и сформируем статистическую выборку  $V1 = (x^i, u^i, i = \overline{1, N})$ .

Нетрудно заметить, что области  $\Omega_t$ ,  $t = \overline{1, M}$ , соответствуют локальным экстремумам-максимумам функции  $y = \phi(x, u)$  и одномодальным фрагментам оценки плотности вероятности  $\bar{p}_\phi(x, u)$ .

Для их обнаружения по выборке  $V1$  может быть использован непараметрический алгоритм автоматической классификации [2].

По данным классификации разобьем исходную выборку  $V$  на группы точек  $V_t$ ,  $t = \overline{1, M}$ , и на их основе построим прямые  $\bar{y} = \bar{\phi}_t(x, u)$  и инверсные  $\bar{u} = \bar{\Phi}'_t(y, x)$  модели в виде непараметрической регрессии для каждой из областей  $\Omega_t$ ,  $t = \overline{1, M}$ . Наличие моделей целевой функции в пределах локальных экстремумов позволяет организовать простую эффективную итерационную процедуру их поиска.

Изложенные принципы этапа самообучения проводятся однажды, а его результаты используются при поиске относительных локальных глобальных экстремумов-максимумов, соответствующих различным значениям  $x$ .

Для определения областей локальных экстремумов, соответствующих конкретному значению  $x = x'$ , по данным классификации синтезируются непараметрические алгоритмы распознавания образов в пространстве  $(x, u)$ .

Оценивание областей локальных экстремумов при конкретных условиях оптимизации осуществляется с помощью непараметрических алгоритмов распознавания образов, исходная информация для синтеза которых формируется на первых этапах самообучения.

После этапов обучения система настроена на поиск относительных глобальных экстремумов. Рассмотрим идею поиска  $t$ -го локального экстремума  $u_t^*$  при  $x = x'$ . В силу выпуклости фрагментов  $y = \phi_t(x', u)$  целевой функции  $\phi(\cdot)$  непараметрическая модель

$$\begin{aligned}\bar{u}_t^*(s) &= \bar{\Phi}'_t(x', y(s)) = \sum_{i \in I_t} u^i \beta^i(x', y(s)) / \sum_{i \in I_t} \beta^i(x', y(s)), \\ \beta^i(x', y(s)) &= \Phi\left(\frac{x' - x^i}{c}\right) \Phi\left(\frac{y(s) - y^i}{c}\right)\end{aligned}\quad (8)$$

инверсной зависимости позволяет при некотором значении  $y(s)$  получить  $s$ -е приближение к локальному экстремуму  $u_t^*$ . Здесь  $\beta(\cdot)$  – многомерные ядерные функции в пространстве  $(x, u)$  [2];  $I_t$  – множество номеров точек из исходной выборки  $V$ , принадлежащих области  $\Omega_t$ . Если  $\phi_t(x', u)$  – симметричная функция, то  $\bar{u}_t^*(s)$  совпадает с  $u_t^*$ .

Иначе, принимая  $y(s+1) = \phi_t(x', \bar{u}_t^*(s)) + \Delta$ , можно на основе (8) организовать быстросходящийся итерационный процесс поиска  $u_t^*$  ( $\Delta$  – некоторая положительная величина, значения которой в общем случае зависят от объема исходной информации и параметра  $s$ ).

Полученные результаты допускают распространение на проблему условной и векторной оптимизации статических систем при неполной информации.

**6. Рандомизированный метод идентификации непараметрических моделей.** Существующий парадокс традиционных методов идентификации стохастических моделей состоит в сопоставлении случайной выборки наблюдений изучаемого объекта с конкретным набором параметров модели, оптимальных в некотором смысле. Рассмотрим рандомизированный подход к определению параметров размытости с непараметрических моделей, основанный на процедуре случайного выбора, что позволяет заменить трудоемкую задачу оптимизации на задачу нахождения законов распределения  $p(c)$ .

Введем обозначения:  $N(x)$  – оператор нормировки компонент вектора  $x = (x_1, \dots, x_k)$  зависимости  $y = \phi(x)$ ;  $D(c)$  – датчик случайных чисел с законом распределения  $p(c)$  на интервале  $(0, h)$ ;  $B(c^i = c)$  – оператор присвоения  $i$ -й ядерной функции непараметрической модели параметра  $c^i = c$ ,  $i = \overline{1, n}$ , где  $n$  – объем обучающей выборки;  $V$ ,  $V_1$  – логические условия, считающиеся выполнеными, если  $i < n$ ,  $j < k$ .

Тогда процедура рандомизированной идентификации представляется в операторной форме записи:

$$A(P(c)) : N(x)(i=1) \downarrow (j=1) \downarrow^2 D(c) B(c^i = c)(j=j+1) V_1 \uparrow^2 (i=i+1) V \uparrow^1.$$

Операторы алгоритма  $A(\cdot)$  функционируют слева направо, при выполнении логического условия происходит переход по стрелке, в противном случае управление передается следующему оператору.

Рассмотрим задачу восстановления плотности вероятности  $p(x)$ ,  $x \in R^1$ , на основе непараметрической оценки  $\bar{p}(x)$  типа Розенблатта – Парзена [1].

Примем  $p(c) = dc$ , где  $d = (t+1)/h^{t+1}$ . Из условия минимума асимптотических разложений среднеквадратических критериев точности аппроксимации  $p(x)$  найдем оптимальные значения  $h^*$ . Можно показать, что отношение указанных критериев для традиционного и рандомизированного методов идентификации  $\bar{p}(x)$  равно  $d' = (1+5t^{-1})^{1/5}/(1+t^{-1})^{-1}$ , которое при  $t \rightarrow \infty$  стремится к 1. Данный факт подтверждает возможность решения проблемы идентификации стохастических моделей. Анализ полученного отношения позволяет выбрать рациональный вид плотностей вероятности. Значения  $d'$  увеличиваются с ростом  $t$  (при  $t=1$   $d'=0,716$ , при  $t=2$   $d'=0,86$ ).

При конечных объемах обучающих выборок наблюдается достоверное превышение статистических оценок:  $d' > 1$ . Причем отношение  $d'$  увеличивается по мере роста уровня помех и сложности восстановления зависимости.

**Заключение.** Рассмотренные направления анализа малых выборок объединяют две основные идеи: создание условий для применения традиционных непараметрических методов статистики и проведение предварительной обработки информации с целью обнаружения дополнительных сведений, повышающих эффективность решения поставленных задач. Выбор того или иного метода зависит от конкретного приложения и особенностей априорной информации. При этом, учитывая системный характер проблем анализа малых выборок, не исключается использование одновременно нескольких подходов для их преодоления.

Перспективным является развитие исследований по следующим направлениям: синтез и анализ решающих правил на основе непараметрической оценки плотности в условиях малых выборок; разработка непараметрических моделей коллективного типа при восстановлении многомерных стохастических зависимостей и их систем. Успешное продвижение в данных направлениях позволит создать теоретическую основу исследования уникальных систем в медицине и экологии.

#### СПИСОК ЛИТЕРАТУРЫ

1. Лапко А. В., Ченцов С. В., Крохов С. И., Фельдман Л. А. Обучающиеся системы обработки информации и принятия решений (непараметрический подход). Новосибирск: Наука, 1996.
2. Лапко А. В. Непараметрические методы классификации и их применение. Новосибирск: Наука, 1993.
3. Лапко А. В., Ченцов С. В. Многоуровневые непараметрические системы принятия решений. Новосибирск: Наука, 1997.

*Поступила в редакцию 16 февраля 1999 г.*