

УДК 681.513

СВОЙСТВА НЕПАРАМЕТРИЧЕСКОЙ РЕШАЮЩЕЙ ФУНКЦИИ ПРИ НАЛИЧИИ АПРИОРНЫХ СВЕДЕНИЙ О НЕЗАВИСИМОСТИ ПРИЗНАКОВ КЛАССИФИЦИРУЕМЫХ ОБЪЕКТОВ

А. В. Лапко¹, В. А. Лапко^{1,2}

¹Институт вычислительного моделирования СО РАН,
660036, г. Красноярск, Академгородок, 50, стр. 44

²Сибирский государственный аэрокосмический университет
им. академика М. Ф. Решетнева,

660014, г. Красноярск, просп. им. газеты «Красноярский рабочий», 31
E-mail: lapko@ict.krasn.ru

Исследуются асимптотические свойства непараметрической оценки уравнения разделяющей поверхности, определённой в пространстве независимых признаков классифицируемых объектов. На этой основе устанавливается значимость влияния априорных сведений о независимости случайных величин на аппроксимационные свойства непараметрической решающей функции в двухальтернативной задаче распознавания образов.

Ключевые слова: распознавание образов, независимые случайные величины, непараметрическая оценка, асимптотические свойства, априорная информация.

Введение. Непараметрические алгоритмы распознавания образов, основанные на оценках плотности вероятности типа Розенблатта — Парзена, широко используются при исследовании объектов различной природы в условиях априорной неопределённости [1].

Разработан ряд модификаций непараметрических классификаторов, ориентированных на условия малых [2] и больших [3, 4] объёмов обучающих выборок и их неоднородный характер [5].

Дальнейшее развитие непараметрических методов распознавания образов заключается в наиболее полном учёте априорных сведений об особенностях изучаемых закономерностей и информации, содержащейся в обучающих выборках [6, 7].

Цель данной работы состоит в обосновании возможности повышения аппроксимационных свойств непараметрической оценки уравнения разделяющей поверхности в двухальтернативной задаче распознавания образов за счёт использования априорной информации о независимости признаков классифицируемых объектов.

Непараметрическая оценка уравнения разделяющей поверхности. Для получения аналитически значимых результатов без существенной потери общности рассмотрим методику построения непараметрического классификатора на примере двухальтернативной задачи распознавания образов в пространстве двух независимых признаков $x = (x_1, x_2)$.

Пусть $V = (x^i, \sigma(i), i = \overline{1, n})$ — обучающая выборка объёма n , составленная из признаков $x^i = (x_1^i, x_2^i)$ классифицируемых объектов и соответствующих им «указаний учителя» $\sigma(i)$ об их принадлежности к одному из двух классов Ω_1, Ω_2 . Вид условных плотностей вероятности $p_r(x_v)$ распределения признаков $x_v, v = 1, 2$, анализируемых объектов в классах $\Omega_r, r = 1, 2$, априори неизвестен.

В данных условиях непараметрическое решающее правило распознавания образов,

соответствующее критерию максимального правдоподобия, имеет вид

$$\bar{m}(x): \begin{cases} x \in \Omega_1, & \text{если } \bar{f}_{12}(x) \leq 0, \\ x \in \Omega_2, & \text{если } \bar{f}_{12}(x) > 0, \end{cases} \quad (1)$$

где

$$\bar{f}_{12}(x) = \bar{p}_2(x_1)\bar{p}_2(x_2) - \bar{p}_1(x_1)\bar{p}_1(x_2) \quad (2)$$

— непараметрическая оценка байесовского уравнения разделяющей поверхности

$$f_{12}(x) = p_2(x_1)p_2(x_2) - p_1(x_1)p_1(x_2)$$

между классами Ω_1, Ω_2 .

Для оценивания плотности вероятности $p_r(x_v)$ по данным обучающей выборки V используем статистику типа Розенблатта — Парзена для одномерного случая [8]

$$p_r(x_v) = \frac{1}{n_r c} \sum_{i \in I_r} \Phi\left(\frac{x_v - x_v^i}{c}\right), \quad v = 1, 2, \quad r = 1, 2, \quad (3)$$

где $n_r = |I_r|$ — количество элементов множества номеров I_r ситуаций из обучающей выборки, принадлежащих к классу Ω_r .

Ядерные функции $\Phi(u)$ в непараметрической оценке плотности вероятности (3), удовлетворяющие условиям H , имеют вид

$$\Phi(u) = \Phi(-u), \quad 0 \leq \Phi(u) < \infty,$$

$$\int \Phi(u) du = 1, \quad \int u^2 \Phi(u) du = 1,$$

$$\int u^m \Phi(u) du < \infty, \quad 0 \leq m < \infty.$$

Здесь и далее бесконечные пределы интегрирования опускаются.

Значения коэффициентов размытости $c = c(n)$ ядерных функций в непараметрической оценке $\bar{f}_{12}(x)$ уравнения разделяющей поверхности убывают с ростом объема n обучающей выборки. Для упрощения последующего анализа аппроксимационных свойств $\bar{f}_{12}(x)$ считается, что интервалы изменения признаков x_1, x_2 классифицируемых объектов сопоставимы. Поэтому появляется возможность полагать значения коэффициентов размытости $c_v(n)$, $v = 1, 2$, соответствующих признакам x_1, x_2 , равными: $c_1(n) = c_2(n) = c(n)$.

Оптимизация непараметрического решающего правила (1) по коэффициенту размытости ядерных функций c осуществляется в режиме «скользящего экзамена» из условия минимума статистической оценки вероятности ошибки распознавания образов

$$\bar{\rho}(c) = \frac{1}{n} \sum_{t=1}^n 1(\sigma(t), \bar{\sigma}(t)),$$

$$1(\sigma(t), \bar{\sigma}(t)) = \begin{cases} 0, & \text{если } \sigma(t) = \bar{\sigma}(t), \\ 1, & \text{если } \sigma(t) \neq \bar{\sigma}(t), \end{cases}$$

где $\bar{\sigma}(t)$ — «решение» о принадлежности ситуации x^t к одному из двух классов, полученное с помощью алгоритма (1). При формировании решения $\bar{\sigma}(t)$ ситуация x^t исключается из процесса обучения в непараметрической статистике (2).

Асимптотические свойства непараметрической оценки уравнения разделяющей поверхности. Справедливо следующее утверждение.

Теорема. Пусть плотности вероятностей $p_r(x_v)$, $r = 1, 2$, $v = 1, 2$, распределения независимых признаков x_1, x_2 анализируемых объектов в классах Ω_1, Ω_2 и первые две их производные ограничены и непрерывны; ядерные функции $\Phi(u)$ удовлетворяют условиям нормированности, положительности и симметричности H ; последовательность $c(n) = c$ коэффициентов размытости ядерных функций такова, что при $n_1 \rightarrow \infty, n_2 \rightarrow \infty$ значения $c \rightarrow 0$, а $n_1 c \rightarrow \infty$ и $n_2 c \rightarrow \infty$. Тогда непараметрическая оценка $\bar{f}_{12}(x)$ байесовского уравнения разделяющей поверхности $f_{12}(x) = p_2(x_1)p_2(x_2) - p_1(x_1)p_1(x_2)$ обладает свойством асимптотической несмещённости и состоятельности.

Доказательство.

1. По определению имеем

$$\begin{aligned} M(\bar{f}_{12}(x)) &= M(\bar{p}_2(x_1)\bar{p}_2(x_2) - \bar{p}_1(x_1)\bar{p}_1(x_2)) = \\ &= \frac{1}{n_2^2 c^2} \sum_{i \in I_2} \sum_{j \in I_2} M\left(\Phi\left(\frac{x_1 - x_1^i}{c}\right)\Phi\left(\frac{x_2 - x_2^j}{c}\right)\right) - \\ &\quad - \frac{1}{n_1^2 c^2} \sum_{i \in I_1} \sum_{j \in I_1} M\left(\Phi\left(\frac{x_1 - x_1^i}{c}\right)\Phi\left(\frac{x_2 - x_2^j}{c}\right)\right) = \\ &= \frac{1}{n_2^2 c^2} \sum_{i \in I_2} \sum_{j \in I_2} \int \int \Phi\left(\frac{x_1 - x_1^i}{c}\right)\Phi\left(\frac{x_2 - x_2^j}{c}\right)p_2(x_1^i)p_2(x_2^j)dx_1^i dx_2^j - \\ &\quad - \frac{1}{n_1^2 c^2} \sum_{i \in I_1} \sum_{j \in I_1} \int \int \Phi\left(\frac{x_1 - x_1^i}{c}\right)\Phi\left(\frac{x_2 - x_2^j}{c}\right)p_1(x_1^i)p_1(x_2^j)dx_1^i dx_2^j = \\ &= \frac{1}{c^2} \int \Phi\left(\frac{x_1 - t_1}{c}\right)p_2(t_1)dt_1 \int \Phi\left(\frac{x_2 - t_2}{c}\right)p_2(t_2)dt_2 - \\ &\quad - \frac{1}{c^2} \int \Phi\left(\frac{x_1 - t_1}{c}\right)p_1(t_1)dt_1 \int \Phi\left(\frac{x_2 - t_2}{c}\right)p_1(t_2)dt_2, \end{aligned}$$

где M — знак математического ожидания.

При выполнении данных преобразований учитывается, что элементы статистических выборок, определяющих каждый r -й класс, являются значениями одной и той же случайной величины $t = (t_1, t_2)$ с плотностью вероятности $p_r(t) = p_r(t_1)p_r(t_2)$, $r = 1, 2$.

Проведём в составляющих последнего выражения замену переменных $x_1 - t_1 = u_1 c$, $x_2 - t_2 = u_2 c$ и, разлагая функции $p_r(x_1 - u_1 c)$, $p_r(x_2 - u_2 c)$, $r = 1, 2$, в ряд Тейлора в точке $x = (x_1, x_2)$, с учётом свойств ядерной функции при достаточно больших значениях n_1, n_2 получим

$$M(\bar{f}_{12}(x) - f_{12}(x)) =$$

$$\begin{aligned}
 &= \frac{c^2}{2} \left(\sum_{r=1}^2 (-1)^r p_r^{(2)}(x_2) p_r(x_1) + \sum_{r=1}^2 (-1)^r p_r^{(2)}(x_1) p_r(x_2) \right) + \\
 &\quad + \frac{c^4}{4} \sum_{r=1}^2 (-1)^r p_r^{(2)}(x_1) p_r^{(2)}(x_2) + 0(c^6). \tag{4}
 \end{aligned}$$

Здесь $p_r^{(2)}(x_1)$, $p_r^{(2)}(x_2)$ — вторые производные плотностей вероятности $p_r(x_1)$, $p_r(x_2)$, $r = 1, 2$, по переменным x_1 , x_2 соответственно; символом $0(c^6)$ обозначены слагаемые порядка малости c^6 и выше.

Отсюда из условия $c \rightarrow 0$ при $n_1 \rightarrow \infty$, $n_2 \rightarrow \infty$ следует свойство асимптотической несмещённости непараметрической статистики $\bar{f}_{12}(x)$.

2. Для доказательства состоятельности непараметрической оценки $\bar{f}_{12}(x)$ уравнения разделяющей поверхности между классами исследуем асимптотические свойства среднеквадратического отклонения

$$\begin{aligned}
 &M \int \int (\bar{f}_{12}(x) - f_{12}(x))^2 dx_1 dx_2 = \int \int M(p_2(x_1)p_2(x_2) - \bar{p}_2(x_1)\bar{p}_2(x_2))^2 dx_1 dx_2 - \\
 &- 2 \int \int M((p_2(x_1)p_2(x_2) - \bar{p}_2(x_1)\bar{p}_2(x_2))(p_1(x_1)p_1(x_2) - \bar{p}_1(x_1)\bar{p}_1(x_2))) dx_1 dx_2 + \\
 &\quad + \int \int M(p_1(x_1)p_1(x_2) - \bar{p}_1(x_1)\bar{p}_1(x_2))^2 dx_1 dx_2. \tag{5}
 \end{aligned}$$

Асимптотическое выражение для среднеквадратического отклонения непараметрической оценки $\bar{p}_r(x_1)\bar{p}_r(x_2)$ произведения плотностей вероятности $p_r(x_1)p_r(x_2)$, $r = 1, 2$, получено в работе [7]:

$$\begin{aligned}
 &\int \int M(p_r(x_1)p_r(x_2) - \bar{p}_r(x_1)\bar{p}_r(x_2))^2 dx_1 dx_2 \sim \\
 &\quad \sim \frac{\|\Phi(u)\|^2 \|p_r(x_2)\|^2}{n_r c} + \frac{\|\Phi(u)\|^2 \|p_r(x_1)\|^2}{n_r c} + \\
 &\quad + \frac{c^4}{4} \int \int (p_r(x_2)p_r^{(2)}(x_1) + p_r(x_1)p_r^{(2)}(x_2))^2 dx_1 dx_2, \tag{6}
 \end{aligned}$$

где

$$\|\Phi(u)\|^2 = \int \Phi^2(u) du; \quad \|p_r(x_v)\|^2 = \int p_r^2(x_v) dx_v, \quad v = 1, 2, \quad r = 1, 2.$$

При формировании выражения (6) величины порядка малости $0(1/n_r)$, $0(1/n_r^2 c^2)$, $0(c/n_r)$, $r = 1, 2$; $0(c^6)$ не учитываются.

Выполняя последовательный анализ составляющих второго слагаемого среднеквадратического отклонения (5), получим его асимптотическое выражение. С учётом независимости случайных величин x_1, x_2 и результатов исследований [9] в условиях $k = 1$ при достаточно больших значениях n_1, n_2 запишем

$$\begin{aligned} & M(p_1(x_1)p_1(x_2)\bar{p}_2(x_1)\bar{p}_2(x_2)) \sim \\ & \sim p_1(x_1)p_1(x_2)\left(p_2(x_1) + \frac{c^2}{2}p_2^{(2)}(x_1)\right)\left(p_2(x_2) + \frac{c^2}{2}p_2^{(2)}(x_2)\right), \end{aligned} \quad (7)$$

$$\begin{aligned} & M(p_2(x_1)p_2(x_2)\bar{p}_1(x_1)\bar{p}_1(x_2)) \sim \\ & \sim p_2(x_1)p_2(x_2)\left(p_1(x_1) + \frac{c^2}{2}p_1^{(2)}(x_1)\right)\left(p_1(x_2) + \frac{c^2}{2}p_1^{(2)}(x_2)\right). \end{aligned} \quad (8)$$

Следуя технологии преобразований, использованной при доказательстве первой части теоремы, нетрудно показать, что при $n_1 \rightarrow \infty$ и $n_2 \rightarrow \infty$

$$\begin{aligned} & M(\bar{p}_1(x_1)\bar{p}_1(x_2)\bar{p}_2(x_1)\bar{p}_2(x_2)) = M(\bar{p}_1(x_1)\bar{p}_2(x_1))M(\bar{p}_1(x_2)\bar{p}_2(x_2)) \sim \\ & \sim \left(p_1(x_1) + \frac{c^2}{2}p_1^{(2)}(x_1)\right)\left(p_2(x_1) + \frac{c^2}{2}p_2^{(2)}(x_1)\right)\left(p_1(x_2) + \frac{c^2}{2}p_1^{(2)}(x_2)\right)\left(p_2(x_2) + \frac{c^2}{2}p_2^{(2)}(x_2)\right). \end{aligned} \quad (9)$$

Подставляя (7)–(9) во второе слагаемое (5), получим его асимптотическое выражение

$$-\frac{c^4}{2} \int \int (p_1(x_1)p_1^{(2)}(x_2) + p_1(x_2)p_1^{(2)}(x_1))(p_2(x_1)p_2^{(2)}(x_2) + p_2(x_2)p_2^{(2)}(x_1))dx_1dx_2.$$

На этой основе, принимая во внимание результаты (6), окончательно запишем асимптотическое выражение среднеквадратического отклонения $\bar{f}_{12}(x)$ от $f_{12}(x)$:

$$\begin{aligned} & M \int \int (\bar{f}_{12}(x) - f_{12}(x))^2 dx_1 dx_2 \sim \\ & \sim \frac{\|\Phi(u)\|^2}{c} \left(\frac{\|p_1(x_1)\|^2 + \|p_1(x_2)\|^2}{n_1} + \frac{\|p_2(x_1)\|^2 + \|p_2(x_2)\|^2}{n_2} \right) + \frac{c^4}{4} \bar{B}, \end{aligned} \quad (10)$$

где

$$\bar{B} = \int \int [(p_1(x_1)p_1^{(2)}(x_2) + p_1(x_2)p_1^{(2)}(x_1)) - (p_2(x_1)p_2^{(2)}(x_2) + p_2(x_2)p_2^{(2)}(x_1))]^2 dx_1 dx_2.$$

Заметим, что при выполнении условий $c \rightarrow 0$, $n_1 c \rightarrow \infty$ и $n_2 c \rightarrow \infty$ для $n_1 \rightarrow \infty$ и $n_2 \rightarrow \infty$ непараметрическая оценка $\bar{f}_{12}(x)$ сходится в среднеквадратическом к байесовскому уравнению разделяющей поверхности $f_{12}(x)$, а с учётом свойства её асимптотической несмещённости является состоятельной.

Анализ свойств статистики $\bar{f}_{12}(x)$. Исследуем влияние априорных сведений о независимости признаков классифицируемых объектов на аппроксимационные свойства непараметрической оценки уравнения разделяющей поверхности. Для этого при оптимальных значениях коэффициентов размытости ядерных функций сравним условия асимптотической сходимости в среднеквадратическом статистики (2) и традиционной непараметрической оценки уравнения разделяющей поверхности

$$\tilde{f}_{12}(x) = \tilde{p}_2(x_1, x_2) - \bar{p}_1(x_1, x_2),$$

где

$$\tilde{p}_r(x_1, x_2) = \frac{1}{n_r c^2} \sum_{i \in I_r} \prod_{v=1}^2 \Phi\left(\frac{x_v - x_v^i}{c}\right), \quad r = 1, 2.$$

В работе [10] установлено, что максимальная эффективность непараметрической решающей функции в задаче распознавания образов достигается при равномерном распределении элементов обучающей выборки между классами. Поэтому определим оптимальные значения \bar{c} статистики (2) из условия минимума выражения (10) при $n_1 = n_2 = n/2$. После очевидных преобразований получим

$$\bar{c} = \left(\frac{2\|\Phi(u)\|^2 \bar{A}}{n\bar{B}}\right)^{1/5}, \tag{11}$$

где

$$\bar{A} = \sum_{r=1}^2 (\|p_r(x_1)\|^2 + \|p_r(x_2)\|^2).$$

Подставляя значения \bar{c} в выражение (10), вычислим его минимальное значение

$$\bar{W} = \frac{5}{4} \left[\left(\frac{2\|\Phi(u)\|^2 \bar{A}}{n}\right)^4 \bar{B} \right]^{1/5}.$$

В соответствии с результатами исследований [11] минимальное среднеквадратическое отклонение традиционной непараметрической оценки $\tilde{f}_{12}(x)$ при $k = 2$ и $n_1 = n_2$ определяется выражением

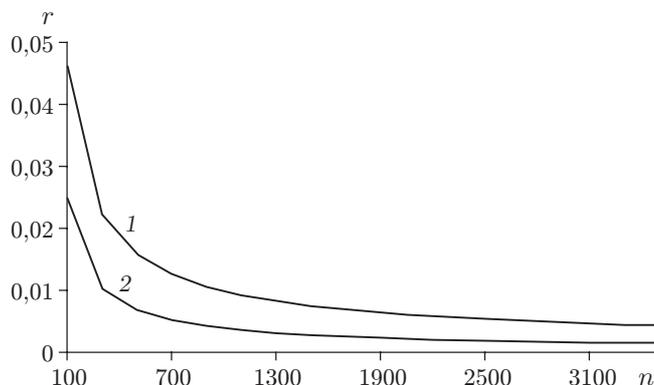
$$\tilde{W} = 3 \left[\left(\frac{(\|\Phi(u)\|^2)^2}{n}\right)^4 \tilde{B}^2 \right]^{1/6},$$

где

$$\tilde{B} = \int \int \left(\sum_{v=1}^2 (p_{2v}^{(2)}(x_1, x_2) - p_{1v}^{(2)}(x_1, x_2)) \right)^2 dx_1 dx_2;$$

$p_{rv}^{(2)}(x_1, x_2)$ — вторая производная плотности вероятности $p_r(x_1, x_2)$ по переменной x_v , $v = 1, 2$.

При конечных $p_r(x_v)$, $p_r^{(2)}(x_v)$, $v = 1, 2$, $r = 1, 2$, с ростом объёма n обучающей выборки значения \bar{W} минимального среднеквадратического отклонения $\tilde{f}(x_1, x_2)$ стремятся к нулю пропорционально величине $r = n^{-4/5}$. Причём порядок подобной сходимости выше, чем



Зависимость порядка сходимости r значений \tilde{W} (кривая 1) и \bar{W} (кривая 2) к нулю от объёма n статистических данных при синтезе непараметрических оценок $\tilde{f}(x_1, x_2)$, $\bar{f}(x_1, x_2)$ уравнений разделяющей поверхности в двухальтернативной задаче распознавания образов

для \tilde{W} , значения которого убывают пропорционально величине $n^{-4/6}$ (см. рисунок). С учётом взаимосвязи между среднеквадратическим отклонением и дисперсией нетрудно заметить, что данная закономерность свойственна и для дисперсий непараметрических оценок решающих функций $\tilde{f}(x_1, x_2)$, $\bar{f}(x_1, x_2)$.

Полученные результаты аналитических исследований обосновывают значимость информации о независимости случайных величин при синтезе непараметрических решающих правил классификации. Кроме того, открывается возможность количественной оценки этой значимости.

Заключение. Наличие априорных сведений о независимости признаков классифицируемых объектов позволяет повысить аппроксимационные свойства непараметрической оценки уравнения разделяющей поверхности в двухальтернативной задаче распознавания образов. Подобная информация может быть определена на этапе предварительного анализа обучающей выборки путём постановки и проверки статистических гипотез о независимости случайных величин. Полученные результаты являются основой для синтеза эффективных непараметрических алгоритмов классификации, соответствующих критерию максимального правдоподобия.

СПИСОК ЛИТЕРАТУРЫ

1. Лапко А. В., Лапко В. А. Непараметрические системы обработки неоднородной информации. Новосибирск: Наука, 2007. 197 с.
2. Лапко А. В., Лапко В. А., Шарков М. А. Непараметрические методы обнаружения закономерностей в условиях малых выборок // Изв. вузов. Сер. Приборостроение. 2008. **51**, № 8. С. 62–67.
3. Лапко А. В., Лапко В. А. Разработка и исследование двухуровневых непараметрических систем классификации // Автометрия. 2010. **46**, № 1. С. 70–78.
4. Лапко А. В., Лапко В. А. Синтез структуры семейства непараметрических решающих функций в задаче распознавания образов // Автометрия. 2011. **47**, № 4. С. 76–82.
5. Лапко А. В., Лапко В. А. Анализ непараметрических алгоритмов распознавания образов в условиях пропуска данных // Автометрия. 2008. **44**, № 3. С. 65–74.
6. Lapko A. V., Lapko V. A. Hybrid systems of pattern recognition // Pattern Recogn. and Image Analysis. 2008. **18**, N 1. P. 7–13.

-
7. **Лапко А. В., Лапко В. А.** Непараметрическая оценка плотности вероятности независимых случайных величин // Информатика и системы управления. 2011. **29**, № 3. С. 118–124.
 8. **Parzen E.** On estimation of a probability density function and mode // Ann. Math. Statistic. 1962. **33**, N 3. P. 1065–1076.
 9. **Епанечников В. А.** Непараметрическая оценка многомерной плотности вероятности // Теория вероятностей и ее применения. 1969. **14**, № 1. С. 156–161.
 10. **Лапко А. В., Лапко В. А.** Анализ асимптотических свойств непараметрической оценки уравнения разделяющей поверхности в двухальтернативной задаче распознавания образов // Автометрия. 2010. **46**, № 3. С. 48–53.
 11. **Лапко А. В., Лапко В. А.** Асимптотические свойства многомерной непараметрической оценки уравнения разделяющей поверхности в двухальтернативной задаче распознавания образов // Системы управления и информационные технологии. 2010. **39**, № 1. С. 16–19.

Поступила в редакцию 16 февраля 2012 г.
