

**СИНТЕЗ НЕПАРАМЕТРИЧЕСКИХ АЛГОРИТМОВ
РАСПОЗНАВАНИЯ ОБРАЗОВ,
ЗАДАННЫХ СЛОЖНЫМИ ЭТАЛОННЫМИ ОПИСАНИЯМИ,
НА ОСНОВЕ АППРОКСИМАЦИИ СТАТИСТИЧЕСКИХ УСРЕД-
НЕННЫХ ФУНКЦИЙ ПРАВДОПОДОБИЯ ПОЛИГОНАМИ СМИР-
НОВА**

д.т.н. Г.В. Певцов, В.Л. Русских, В.А. Лупандин

Разработан метод синтеза непараметрических алгоритмов распознавания образов, заданных сложными эталонными описаниями в виде совокупностей эталонных интервалов и (или) дискретных значений признаков. Обучение алгоритма основано на получении полигональных оценок статистических усредненных функций правдоподобия по Смирнову.

Постановка проблемы и анализ литературы. При разработке аппаратуры диагностики и контроля физических, химических, биологических и других процессов часто возникает необходимость синтеза алгоритмов распознавания образов, заданных сложными эталонными описаниями в виде интервалов возможных значений и (или) совокупностей дискретных эталонных значений признаков (параметров процессов). Для решения задач такого типа в [1 – 4] и др. разработана методика синтеза алгоритмов распознавания на основе проверки сложных статистических гипотез путем сравнения статистик отношений усредненных функций правдоподобия с порогом. При синтезе алгоритмов, реализующих разработанную методику, эталонные описания образов определяются в предположении о том, что виды и параметры априорных распределений известны. Однако в практике создания систем распознавания образов чаще возникает необходимость в алгоритмах, которые могут обучаться до или в процессе ведения распознавания. Одним из наиболее простых, но достаточно эффективных методов обучения является построение сравниваемых статистик гистограммным методом с последующим выравниванием полигонами Смирнова [5].

Целью статьи является развитие методики синтеза алгоритмов распознавания образов, заданных сложными эталонными описаниями, на случай непараметрического обучения путем построения по Смирнову полигональных оценок усредненных статистических функций правдопо-

добия.

Пусть на множестве U объектов распознавания наблюдается L образов $U_i \subset U$, $i \in \{1, 2, \dots, L\}$, представляющих собой множества (группы) объектов распознавания. Каждый из образов проявляется в метрике \mathfrak{Z} -мерного евклидового пространства признаков S . В метрике каждого признака s_j , $j \in \{1, 2, \dots, \mathfrak{Z}\}$, каждому образу априорно может соответствовать v_i элементов — эталонных значений и (или) интервалов эталонных значений признака, описывающих группу объектов распознавания. Неизвестное априорное распределение вектора признаков $\mathbf{s} = \{s_1, s_2, \dots, s_j, \dots, s_{\mathfrak{Z}}\}$ для каждого i -го образа представляет собой \mathfrak{Z} -мерную совместную плотность вероятности смешанного типа $W(\mathbf{s} | U_i) = w_i(\mathbf{s})$ вектора \mathbf{s} на множестве U_i , определенную в области S_i пространства признаков. По результатам Ξ испытаний для каждого из образов в метрике каждого признака s_j , $j \in \{1, 2, \dots, \mathfrak{Z}\}$, получены первичные статистические совокупности, из которых сформированы группированные статистические ряды. Выдвигается L гипотез H_1, H_2, \dots, H_L о том, что наблюдаемая выборка x ζ -кратно измеренных значений \mathfrak{Z} признаков принадлежит одному из образов U_i . Задача состоит в установлении до наблюдения дискретно-аналогового нерандомизированного статистически оптимального правила δ , реализующего разделение $\zeta \times \mathfrak{Z}$ -мерного евклидового пространства выборок X на L непересекающихся областей X^*_q , $q \in \{1, 2, \dots, L\}$, $\bigcup_{q=1}^L X^*_q = X$, и при-

писывающего каждой из этих областей одного из L решений γ_q о принятии гипотезы H_q .

Опишем аналитически полигональную оценку w^*_{ijn} произвольной одномерной эмпирической дифференциальной функции распределения, соответствующей n -му элементу, $n \in \{1, 2, \dots, v_i\}$, i -го образа в метрике j -го признака, в виде [5]:

$$w^*_{ijn}(x_j) = \frac{1}{\Xi_{ijn}\Delta s_j} \left[0,5(\Xi_{ijnk} + \Xi_{ijn(k+1)}) + \frac{1}{\Delta s_j} (x_j - k_j\Delta s_j)(\Xi_{ijn(k+1)} - \Xi_{ijnk}) \right]; \quad (1)$$

$$k_j = \text{ent}(x_j/\Delta s_j); \quad x_j \in [k_j\Delta s_j - 0,5\Delta s_j, k_j\Delta s_j + 0,5\Delta s_j],$$

где Ξ_{ijnk} — количество выборочных значений j -го признака, попавших в k -й интервал $[(k-1)\Delta s_j, k\Delta s_j]$ при наблюдении (в ходе испытаний) n -го элемента i -го образа; Ξ_{ijn} — количество наблюдений n -го элемента i -го образа в метрике j -го признака; $\text{ent}(\cdot)$ — символ операции округления.

Статистики i -х элементов

$$\Lambda_i(\mathbf{x}) = w_i(\mathbf{x})/w_1(\mathbf{x}) \quad (2)$$

вектора отношений усредненных статистических функций правдоподобия [5]:

$$w_i(\mathbf{x}) = W(\mathbf{x}|U_i) = \int_{S_i} w_i(\mathbf{s})W(\mathbf{x} | \mathbf{s})d\mathbf{s} \quad (3)$$

определим в соответствии с [1 – 4], полагая признаки и наблюдаемые выборки независимыми:

$$w_i(\mathbf{x}) = \prod_{j=1}^{\mathfrak{Z}} \left[\sum_{r=1}^{R_{ij}} I_{ijr} p_{ijr} \int_{S_{ij}} w_{ijr}(s_j, s'_{ijr}, s''_{ijr}) W(\mathbf{x} | s_j) ds_j + \sum_{d=1}^{D_{ij}} I_{ijd} p_{ijd} W(\mathbf{x} | s_{ijd}) \right]; \quad (4)$$

$$\sum_{r=1}^{R_{ij}} p_{ijr} + \sum_{d=1}^{D_{ij}} p_{ijd} = 1, \quad \sum_{r=1}^{R_{ij}} I_{ijr} p_{ijr} + \sum_{d=1}^{D_{ij}} I_{ijd} p_{ijd} = 1,$$

$$\forall i \in \{1, 2, \dots, L\}, \quad \forall j \in \{1, 2, \dots, \mathfrak{Z}\},$$

где $w_{ijr}(s_j, s'_{ijr}, s''_{ijr})$ – априорные плотности распределения признака s_j на каждом из R_{ij} эталонных интервалов $[s'_{ijr}, s''_{ijr}]$, $r \in \{1, 2, \dots, R_{ij}\}$; $\delta(s_j - s_{ijd})$ – функции Дирака, как плотности вероятности математических ожиданий s_{ijd} каждого из D_{ij} возможных дискретных эталонных значений признака s_j , $d \in \{1, 2, \dots, D_{ij}\}$; p_{ijr} и p_{ijd} – априорные условные вероятности наблюдения r -го интервала или d -го значения при наблюдении образа U_i в метрике признака s_j ; $I_{ijr(d)} \in [0, 1]$ – коэффициенты, характеризующие относительную степень информативности r -го интервала или d -го значения признака s_j при распознавании образа U_i ; $W(\mathbf{x} | \mathbf{s})$ — зависящая от значений вектора параметров \mathbf{s} функция правдоподобия наблюдаемой выборки \mathbf{x} ; S_i – область определения образа U_i в пространстве признаков \mathbf{S} , S_{ij} – область определения образа U_i в метрике признака s_j .

Для нахождения оценок (2), (3) подставим в (4) вместо

$$\int_{S_{ij}} w_{ijr}(s_j, s'_{ijr}, s''_{ijr}) W(\mathbf{x} | s_j) ds_j, \quad W(\mathbf{x} | s_{ijd}), \quad p_{ijr} \text{ и } p_{ijd} \text{ их оценки.}$$

Первые два элемента получим из (1) заменой индексов p на r и d , соответственно. Оценки априорных вероятностей p_{ijr} и p_{ijd} определим отношениями:

$$p^*_{ijr} = \Xi_{ijr} / \Xi_i;$$

$$p^*_{ijd} = \Xi_{ijd} / \Xi_i$$

количества проявлений r -го интервала Ξ_{ijr} и d -го значения Ξ_{ijd} i -го образа в метрике j -го признака к количеству Ξ_i наблюдений i -го образа. В ре-

зультате из (1), (4) имеем:

$$w^*_{i}(x) = \frac{1}{\Xi_i} \prod_{j=1}^{\tilde{\mathfrak{S}}} \frac{1}{\Delta s_j} \left\{ \sum_{r=1}^{R_{ij}} \frac{I_{ijr}}{\varpi_{ijr}} \left[0,5(\Xi_{ijrk} + \Xi_{ijr(k+1)}) + \frac{1}{\Delta s_j} (x_j - k_j \Delta s_j) (\Xi_{ijr(k-1)} - \Xi_{ijrk}) \right] + \sum_{d=1}^{D_{ij}} \frac{I_{ijd}}{\varpi_{ijd}} \left[0,5(\Xi_{ijdk} + \Xi_{ijd(k+1)}) + \frac{1}{\Delta s_j} (x_j - k_j \Delta s_j) (\Xi_{ijd(k+1)} - \Xi_{ijdk}) \right] \right\}; \quad (5)$$

$$k_j = \text{ent}(x_j / \Delta s_j); \quad x_j \in [k_j \Delta s_j - 0,5 \Delta s_j, k_j \Delta s_j + 0,5 \Delta s_j],$$

где $\varpi_{ijn} = \int_{-\infty}^{\infty} w^*_{ijn}(x_j) dx_j$ – коэффициент, с помощью которого компенсируется возможное (из-за погрешностей интерполяции) отличие площади под ломаной (1) от единичного значения.

Подставляя (5) в (2), получаем полигональные оценки отношений правдоподобия для непараметрических алгоритмов распознавания образов, заданных сложными эталонными описаниями. Синтезируемые алгоритмы распознавания предполагают сравнения полученных отношений правдоподобия с порогом, значение которого определяется выбранным критерием эффективности [1 – 4] с учетом оценок p^*_i априорных вероятностей наблюдения образов U_i , $p^*_i = \Xi_i / \Xi$, $\sum_{i=1}^L p^*_i = 1$.

При анализе синтезированных алгоритмов необходимо получить оценку полной вероятности ошибки $p_{\text{ош}}$ вида

$$p^*_{\text{ош}} = \sum_{i=1}^L p^*_{\text{ош}i} = \sum_{i=1}^L p^*_i \sum_{\substack{q=1 \\ q \neq i}}^L P^* \{ \gamma_q | U_i \}; \quad \bigcup_{i=1}^L X^*_i = X; \quad \bigcap_{i=1}^L X^*_i = \emptyset. \quad (6)$$

Входящие в (6) оценки $P^* \{ \gamma_q | U_i \}$ полных вероятностей принятия ошибочных решений γ_q при наблюдении образа U_i определяются как усредненные по эталонным описаниям образов оценки условных вероятностей ошибок [3, 4]:

$$P^* \{ \gamma_q | U_i \} = \int_{X^*_q} w^*_{i}(x) dx. \quad (7)$$

Из (5) – (7) имеем асимптотическую оценку полной вероятности ошибки:

$$p^*_{\text{ош}} = \frac{1}{\Xi} \sum_{i=1}^L \frac{1}{\Xi_i} \sum_{\substack{q=1 \\ q \neq i}}^L \int_{X^*_q} \prod_{j=1}^{\tilde{\mathfrak{S}}} \frac{1}{\Delta s_j} \left\{ \sum_{r=1}^{R_{ij}} \frac{I_{ijr}}{\varpi_{ijr}} \left[0,5(\Xi_{ijrk} + \Xi_{ijr(k+1)}) + \frac{1}{\Delta s_j} (x_j - k_j \Delta s_j) \right] \times \right.$$

$$\times \left(\Xi_{ijr(k+1)} - \Xi_{ijrk} \right) \left] + \sum_{d=1}^{D_{ij}} \frac{I_{ijd}}{\varpi_{ijd}} \left[0,5(\Xi_{ijdk} + \Xi_{ijd(k+1)}) + \frac{1}{\Delta s_j} (x_j - k_j \Delta s_j) (\Xi_{ijd(k+1)} - \Xi_{ijdk}) \right] \right] dx ; \quad (8)$$

$$k_j = \text{ent}(x_j / \Delta s_j); \quad x_j \in [k_j \Delta s_j - 0,5 \Delta s_j, k_j \Delta s_j + 0,5 \Delta s_j].$$

Выводы. Таким образом, разработанный метод позволяет синтезировать непараметрические алгоритмы распознавания образов, заданных сложными эталонными описаниями, с обучением путем получения первичных статистических совокупностей и формирования из них отношений усредненных статистических функций правдоподобия, выровненных полигонами Смирнова.

ЛИТЕРАТУРА

1. Певцов Г.В. Синтез алгоритма распознавания радиоизлучений на основе байесовского правила проверки сложных гипотез // Радиоэлектроника (Изв. высш. учебн. заведений). – 1998. – № 4. – С. 49 – 57.
2. Певцов Г.В. Синтез алгоритмов распознавания образов, заданных сложными эталонными описаниями в метрике азимутов на источники радиоизлучений // Радиоэлектроника (Изв. высш. учебн. заведений). – 2000. – № 4. – С. 38 – 45.
3. Певцов Г.В., Лупандин В.А. Синтез алгоритмов многоальтернативного распознавания образов на основе проверки сложных статистических гипотез по критерию максимума апостериорной вероятности // Радиоэлектроника (Изв. высш. учебн. заведений). – 2001. – № 11. – С. 77 – 80.
4. Певцов Г.В. Синтез байесовских алгоритмов многоальтернативного распознавания образов, заданных сложными эталонными описаниями // Радиоэлектроника (Изв. высш. учебн. заведений). – 2003. – № 1. – С. 58 – 63.
5. Фомин Я.А., Тарловский Г.Р. Статистическая теория распознавания образов. – М.: Радио и связь, 1986. – 264 с.
6. Левин Б.Р. Теоретические основы статистической радиотехники. Книга 2. – М.: Сов. радио, 1975. – 392 с.

Поступила 26.06.2003

ПЕВЦОВ Геннадий Владимирович, доктор техн. наук, ст. научн. сотр., зам. начальника научного центра при ХВУ по научной работе. В 1983 году окончил Киевское ВИРТУ ПВО. Область научных интересов – обработка радиотехнических сигналов и информации.

РУССКИХ Виктор Леонидович, начальник отдела – заместитель начальника Главного штаба Войск ПВО по военно-научной работе. В 1989 году окончил ВА ПВО СВ им. А.М. Василевского. Область научных интересов – военная кибернетика.

ЛУПАНДИН Владимир Анатольевич, адъюнкт ХВУ. В 1992 году окончил Харьковское ВВКИУРВ. Область научных интересов – обработка радиотехнических сигналов и информации.
