

Б. Д. БОРИСОВ

(Новосибирск)

АДАПТИВНЫЙ МЕТОД ПОСТРОЕНИЯ ЭТАЛОНОВ В ЗАДАЧАХ РАСПОЗНАВАНИЯ ОБРАЗОВ

Проблема формирования эталонов в задачах распознавания, как правило, возникает при разрешении многоальтернативных гипотез, когда число классов образов $K \gg 2$. Обычный подход, состоящий в построении разделяющей поверхности между каждой парой классов и сводящий решение к набору дихотомий, неэффективен, поскольку затягивает процесс обучения и требует запоминания значительного количества коэффициентов разложения разделяющих поверхностей. Поэтому целесообразно определить разделяющую поверхность как оболочку, охватывающую собственную область класса в пространстве измерений (признаков), характеризующих образ. При таком подходе число поверхностей равно числу классов и задача сводится к нахождению контура равновероятной плотности — оболочки, удовлетворяющей условию [1]

$$p(\bar{X}/K) = \text{const.} \quad (1)$$

Поскольку оценка многомерной плотности распределения $p(\bar{X})$ сопряжена с большими вычислительными трудностями, аппроксимацию контура можно осуществлять с помощью некоторого набора «эталонных» отражающего форму этого многомерного распределения.

Формирование эталонов для детерминированных задач при запоминании всей обучающей выборки рассматривалось в работах И. Т. Турбовича [2, 3]. Г. С. Себастиан предложил адаптивный метод построения обучающих изображений, основанный на гауссовой аппроксимации плотностей вероятности [4]. В данной статье предлагается адаптивный метод, приводящий к значительно меньшему числу эталонов, чем в [4], и не требующий предварительного хранения обучающей выборки. Этот метод пригоден для статистических ситуаций (с пересекающимися областями классов в пространстве признаков), и позволяет реализовать обучающийся классификатор с небольшим объемом памяти.

Определим эталон как замкнутое (не обязательно выпуклое) геометрическое тело в многомерном пространстве признаков. Задача состоит в отыскании минимального числа эталонов, аппроксимирующих распределение $p(X)$. Известные способы оценки $p(\bar{X})$ с помощью простых эталонов в виде гиперсфер или гиперкубов [5] приводят к объемам памяти, исключающим их практическую реализацию. Поэтому для сокращения объема памяти распознающей системы необходим механизм «укрупнения» элементарных эталонов. В качестве такого механизма

предлагается использовать метод отображения многомерного пространства на одномерное с сохранением меры [6]. В [7] рассмотрены два типа таких преобразований, используемых для вывода информации ЭВМ на экран индикатора (Display). Идея метода состоит в сканировании определенным образом многомерного пространства, разбитого на элементарные области (гиперкубы), и отображении пути сканирования в порядок следования интервалов на одномерной оси. Это отображение позволяет объединять соседние интервалы в более крупные и хранить их как эталоны. Поскольку мера на прямой равняется мере l измерений, то последняя операция эквивалентна укрупнению элементарных эталонов в l -мерном пространстве признаков. Ситуация хорошо иллюстрируется рис. 1, где нормированное двумерное пространство отображается на одномерную ось R . Соответствие n -го интервала e_n n -му гиперкубу определяется выражением

$$e_n = a_{11} b^{kl-1} + a_{21} b^{kl-2} + \dots + a_{j1} b^0, \quad (2)$$

где b — целое положительное число, основание системы; k при выбранном b определяет размер (число) гиперкубов в l -мерном пространстве, общее число которых равно b^{kl} ; a_j — коэффициенты, принимающие одно из значений $0, 1, 2, \dots, b-1$ для $i=1, 2, \dots, k; j=1, 2, \dots, l$; значения a_{ji} находятся для j -й координаты из выражения

$$e_j = a_{j1} b^{k-i} + a_{j2} b^{k-2} + \dots + a_{jk} b^0. \quad (3)$$

Значение интервала e_j по j -й координате в (3) определяется из условия

$$e_j \leq b^k x_j < e_j + 1, \quad (4)$$

где x_j — составляющая вектора признаков \bar{X} .

Квадраты 1, 2, 3, 4, 5, ... (см. рис. 1) отображаются в соседние интервалы на R . Если в эти квадраты попадают векторы признаков одного класса, например C , то, объединив соответствующие им интервалы в один с границами 1—5, получим укрупненный эталон (C_1). Очевидно, что размер эталона зависит от вида преобразования, которое выбирается из условий простоты реализации и производимого числа эталонов. Однако любое преобразование такого рода позволяет сгруппировать элементарные ячейки в ограниченное число эталонов, аппроксимирующих распределение векторов признаков.

Сравним эффективность такого подхода с уже известными [2, 4] по критериям, приведенным в таблице. Для детерминированной задачи выберем пример, приведенный в [3], для 3 классов (A, B, C), распределение которых показано на рис. 1. Результаты сравнения приведены в таблице. Отметим, что метод Н. Т. Турбовича, обеспечивая минимум




Рис. 1.

| Метод формирования эталонов | Число эталонов для 3 классов (рис. 1) | Тип задач распознавания | Обработка данных |
|-----------------------------|---------------------------------------|-----------------------------------|----------------------------------|
| По Турбовичу | 7 | Детерминированные | С предварительным запоминанием |
| По Себестиану | 39 | Статистические, детерминированные | Адаптивная (по мере поступления) |
| Метод отображения | 16 | Статистические, детерминированные | Адаптивная |

эталон, требует предварительного запоминания всей выборки и сложных вычислений на ЭВМ.

Рассмотрим возможность использования метода отображения для статистической задачи распознавания. С этой целью дополнительно запомним число реализаций N , попадающих в эталон, и длину эталона n (число элементарных ячеек в нем). Тогда величина $p_i = \frac{N}{n}$ даст оценку

плотности вероятности в i -м эталоне. Для вектора \bar{X} , попадающего в несколько эталонов, принимается решение в пользу того, у которого $p_{i_{\max}}$. Незначительное увеличение памяти (до 20%) в этом случае позволяет охватить полный круг задач распознавания.

Проиллюстрируем это примером распознавания 2 двумерных гауссовых распределений с параметрами:

| Класс | Математическое ожидание | Ковариация |
|-------|--|--|
| N_A | $\begin{bmatrix} 0 \\ 0 \end{bmatrix}$ | $\begin{bmatrix} 1 & 0 \\ 0 & 4 \end{bmatrix}$ |
| N_B | $\begin{bmatrix} 2 \\ 2 \end{bmatrix}$ | $\begin{bmatrix} 1 & 0 \\ 0 & 4 \end{bmatrix}$ |

Оптимальное решение (байесова оценка) на этих распределениях дает вероятность ошибки $P(\epsilon) = 0,095$, метод отображения $P^*(\epsilon) = 0,168$ при $l=2, b=2, k=3$ и 11 эталонах (4 для класса А, 7 для класса В). Увеличение k приведет к снижению вероятности ошибки. Так, при $k=4$ $P^*(\epsilon) = 0,152$.




Рис. 2.

Метод отображения позволяет синтезировать автоматический классификатор с ограниченным объемом памяти и адаптивной (по мере поступления) обработкой данных.

Блок-схема такого классификатора изображена на рис. 2. Рассмотрим процесс формирования эталонов в режиме обучения, предполагая, что память классификатора вначале пуста. С приходом первого вектора X_1^k класса K в блоке П последовательно вычисляются (4), (3), (2) и определяется соответствующий этому вектору интервал на R , адрес (номер) которого заносится в запоминающее устройство (ЗУ) как первый эталон k_1 класса K . С приходом второй реализации (вектора \bar{X}_2^k)

определяется соответствующий ему номер интервала e_2 и проверяется условие

$$e_1 - e_2 = \begin{cases} 0; \\ \pm 1, \end{cases} \quad (5)$$

которое выявляет либо попадание \bar{X}_2^k в первый эталон, либо соседство интервалов e_1 и e_2 . В первом случае содержимое ячейки памяти (адрес) e_1 не меняется, а во втором — запоминается адрес укрупненного эталона в виде 2 адресов его левой $e_{1(2)}$ и правой $e_{2(1)}$ границ (см. рис. 1). Если условие (5) не выполняется, в ЗУ образуется новый эталон. Последующие реализации сравниваются аналогично с каждым эталоном. Таким образом, адресная часть эталона содержит (для $b=2$) $2 \cdot 2^{kl}$ бит. В режиме классификации производится вычисление e_x для вектора неизвестной принадлежности \bar{X} и выявляется (в блоке сравнения адреса СА) попадание e_x в один из хранящихся в ЗУ эталонов с индикацией класса этого эталона. Этот процесс напоминает адаптивный метод Г. С. Себестиана, однако, в отличие от последнего, нечувствителен к порядку предъявления реализаций и позволяет резко уменьшить число эталонов (объем памяти) путем их «укрупнения». При построении систем классификации с обучением это преимущество является решающим.

ЛИТЕРАТУРА

1. А. Г. Сенин. Об одном способе формирования поверхности равной плотности вероятности при распознавании шумов.— Труды II Всесоюзного симпозиума по методам представления и аппаратному анализу случайных процессов и полей, т. II. Новосибирск, 1969.
2. Опознавание образов. Под ред. Н. Т. Турбовича. М., «Наука», 1968.
3. Опознавание образов. Теория передачи информации. ИГиП АН СССР. М., «Наука», 1965.
4. Г. С. Себестян. Процессы принятия решений при распознавании образов. Киев, «Техника», 1965.
5. T. A. Elkins. Cubical and Spherical Estimation of Multivariate Probability Density.— Journ. of the American Statistical Association, 1968, v. 63, № 324.
6. Н. Винер. Интеграл Фурье и некоторые его приложения. М., Физматгиз, 1963.
7. E. A. Patrick, D. R. Anderson, F. K. Beehtel. Mapping Multidimensional Space to one Dimension for Computer Output Display.— IEEE Trans. on Computer, 1968, v. C—17, № 10.

Поступила в редакцию
10 июля 1970 г.