

Об одном методе реализации процедуры обучения при построении системы распознавания образов

В. Г. Родченко

Введение

Использование методов прикладной статистики и математической теории распознавания образов часто является единственно возможной альтернативой применению традиционного математического аппарата при проведении научных исследований и при решении большого числа прикладных задач, связанных с моделированием поведения многомерных объектов и сложных систем [1].

Современный подход к проблеме построения системы распознавания предусматривает решение двух взаимосвязанных задач – *обучения* и *принятия решения (контроля)* [2]. Только совместное решение этих задач решает проблему в целом и позволяет перейти к конкретному практическому использованию методов математической теории распознавания образов [3]. Реализация процедуры *обучения* непосредственно связана с анализом данных, которые априори представляют собой исходную *классифицированную обучающую выборку* (КОВ). Такая выборка образуется путем объединения данных об объектах, которые изначально классифицированы и описываются с помощью множества признаков, составляющих априорный словарь.

В реальных системах распознавания формирование *априорного словаря признаков* (АСП) начинается с построения *пространства наблюдений* (ПН) для соответствующих объектов. При этом необходимо в ПН включать такие характеристики объектов, которые обеспечили бы разделение различных классов в этом пространстве. Фактически АСП получается в результате формализации пространства наблюдений и представляет собой выборку из *генерального словаря признаков*. Практический опыт построения АСП свидетельствует о том, что часть признаков, включаемых в априорный словарь, не несёт в себе разделяющую функцию, а потому эти признаки создают “шумы” при идентификации образов объектов и классов и, как следствие, приводят к искажению достоверности процедуры распознавания [4].

В данной статье предлагается метод реализации процедуры обучения на основе анализа данных из исходной классифицированной обучающей выборки, который предусматривает построение рабочего словаря, включающего в себя только информативные признаки с точки зрения разделения образов классов в соответствующем признаковом пространстве. Для выделения из априорного словаря указанных информативных признаков предлагается использовать статистические критерии однородности, а проверку достоверности процедуры принятия решения реализовать с помощью алгоритмов кластерного анализа типа FOREL-2, которые ориентированы на построение заранее заданного числа кластеров.

Описание метода обучения

Процедура обучения при реализации системы распознавания строится на основе использования исходной классифицированной обучающей выборки. Процесс построения КОВ предполагает предварительное формирование *алфавита классов* и определение исходного *пространства наблюдений*. Отметим, что процедура формирования алфавита классов обычно особых затруднений не вызывает, тогда как определение пространства наблюдений является нетривиальной задачей, содержащей в себе ряд “тонких” моментов, которые могут в дальнейшем способствовать искажению достоверности результатов распознавания или даже приводить к серьезным ошибкам.

Процесс формирования пространства наблюдений часто трудно формализуется и плохо поддается автоматизации. При разработке систем распознавания для формирования ПН привлекаются квалифицированные эксперты, а это способствует повышению роли субъективного фактора. После определения пространства наблюдений проводится формализация, и в итоге строится априорный словарь признаков. Фактически любой априорный словарь представляет собой выборку из генерального словаря признаков, а следовательно, можно сформировать *приемлемый* для построения системы распознавания АСП, но нельзя сформировать оптимальный словарь. Кроме того, не исключается ситуация, когда в априорный словарь попадут такие признаки, которые не обеспечивают разделение классов в соответствующем признаковом пространстве, то есть в этом случае речь идет о *неприемлемом* для распознавания варианте априорного словаря.

Предположим, что имеется алфавит классов $A = \{A_1, A_2, \dots, A_k\}$ и сформирован априорный словарь признаков $P = \{P_1, P_2, \dots, P_n\}$. Каждый отдельный объект описывается n признаками из АСП и однозначно ассоциируется с одним из классов, а каждый класс A_i (где $i = \overline{1, k}$) образуется путем объединения m_i (где $i = \overline{1, k}$) многомерных объектов.

Вектор-столбец $\begin{pmatrix} x_{1j} \\ \vdots \\ x_{nj} \\ i \end{pmatrix}$ (где $j = \overline{1, m_i}$) задает формальное описание j -го объекта i -го класса.

Объединение всех таких векторов, описывающих объекты одного и того же класса, образует матрицу, которая представляет собой формальное описание соответствующего i -го класса в многомерном априорном признаковом пространстве и имеет вид:

$$X_{n \times m_i}^i = \begin{pmatrix} x_{11}^i & x_{12}^i & \dots & x_{1m_i}^i \\ x_{21}^i & x_{22}^i & \dots & x_{2m_i}^i \\ \dots & \dots & \dots & \dots \\ x_{n1}^i & x_{n2}^i & \dots & x_{nm_i}^i \end{pmatrix}, \text{ где } i = \overline{1, k}; j = \overline{1, m_i}.$$

В итоге классифицированная обучающая выборка $X_{n \times m}$ (где n – количество признаков априорного словаря, а $m = m_1 + m_2 + \dots + m_k$, где k – количество классов) будет получаться путем объединения всех соответствующих матриц вида $X_{n \times m_i}^i$, т.е. $X_{n \times m} = \bigcup_{i=1}^k X_{n \times m_i}^i$.

После завершения формирования классифицированной обучающей выборки сразу же можно воспользоваться процедурой кластеризации с целью исследования возможности использования признаков из АСП для построения эталонов классов. В данном случае, в-первых, следует воспользоваться алгоритмами кластеризации, которые ориентированы на построение точно заданного количества кластеров, во-вторых, число кластеров должно равняться количеству классов k . Если в итоге выполнения процедуры кластеризации оказалось, что в состав соответствующих кластеров вошли в подавляющем большинстве представители одного класса и не превышен допустимый пороговый уровень ошибочных включений объектов в другие классы, то на основе признаков из АСП можно строить эталоны классов и проводить процедуру принятия решения. Иначе же необходимо провести дополнительный разведочный анализ информативности признаков.

По степени информативности (с точки зрения отражения характерных для каждого класса индивидуальных свойств) признаки, попадающие в априорный словарь, следует сепарировать на три вида [5].

К первому виду относятся те признаки из АСП, значения которых фактически подчиняются одному и тому же закону распределения для всех классов $A = \{A_1, A_2, \dots, A_k\}$. Природа этих признаков такова, что они не несут разделяющей разницы между классами, а потому со-

здают “шумы” и на этапе обучения системы (размывая эталоны классов), и в процессе выполнения процедуры принятия решения (искажая распознаваемый образ).

Признаки будут отнесены ко второму виду, если в результате сопоставления всех пар выборок значений этих признаков из разных классов оказалось, что не выполняются соответствующие статистические критерии однородности. Свойства признаков этого вида таковы, что обеспечивается разделение образов классов в многомерном признаковом пространстве. Именно эти признаки будут включаться в словарь информативных признаков, на основе которого будет выполняться процедура построения компактных и разделенных в многомерном признаковом пространстве эталонов классов, а затем будет выполняться и процедура принятия решения (распознавания исследуемого объекта).

Если в процессе проводимого анализа очередной признак не является представителем ни первого, ни второго вида, то его относят к третьему виду. Такие признаки не отражают какие-либо четко выраженные внутриклассовые и межклассовые особенности, а потому размывают образы эталонов классов на этапе обучения, тем самым провоцируя серьезные помехи для качественного выполнения процедуры принятия решения.

Описание алгоритма реализации метода

Алгоритм реализации процедуры обучения при построении системы распознавания образов предполагает выполнение следующих семи шагов:

Шаг 1. Формируются алфавит классов $A = \{A_1, A_2, \dots, A_k\}$ и определяется исходное пространство наблюдений, на основе которого в итоге строится априорный словарь признаков $P = \{P_1, P_2, \dots, P_n\}$.

Шаг 2. Каждый класс A_i (где $i = \overline{1, n}$) изначально определяется совокупностью объектов. В свою очередь, каждый отдельный объект (на основе признаков из априорного словаря) описывается в многомерном признаковом пространстве в виде вектора-столбца $x^T = (x_1, x_2, \dots, x_n)$, где x_i – значение i -го признака.

Шаг 3. Формируется классифицированная обучающая выборка путем объединения всех соответствующих векторов из всех классов. Эта выборка представляет собой прямоугольную матрицу, состоящую из n строк и m столбцов (где $m = m_1 + m_2 + \dots + m_k$, а m_i – количество объектов i -го класса). При этом для $\forall A_i \subset A$ ($i = \overline{1, k}$) формируется матрица X_i размерности $n \times m_i$, где m_i – число объектов i -го класса.

Шаг 4. Используя алгоритм кластеризации типа Fogel-2, строится k кластеров, и проводится анализ их содержимого. Если каждый кластер содержит в основном объекты одного класса и не превышает допустимое пороговое значение ошибочных включений объектов в кластеры, то все признаки из априорного словаря переносятся в словарь информативных признаков. Далее осуществляется переход к шагу 6 этого алгоритма, а иначе выполняется следующий шаг.

Шаг 5. Последовательно анализируются все признаки из априорного словаря $P = \{P_1, P_2, \dots, P_n\}$, и в результате они сепарируются на три вида: $P^{(1)} = \{P_1^{(1)}, P_2^{(1)}, \dots, P_{n_1}^{(1)}\}$, $P^{(2)} = \{P_1^{(2)}, P_2^{(2)}, \dots, P_{n_2}^{(2)}\}$, $P^{(3)} = \{P_1^{(3)}, P_2^{(3)}, \dots, P_{n_3}^{(3)}\}$, где $P = P^{(1)} \cup P^{(2)} \cup P^{(3)}$ и $n_1 + n_2 + n_3 = n$.

Очередной признак P_i (где $i = \overline{1, n}$) классифицируется к одному из указанных выше видов на основе правила:

– если для всех пар классов соответствующий критерий однородности не показал существенного различия между выборками значений этого признака для двух сравниваемых классов, то P_i относится к первому виду;

– если для всех пар классов соответствующий критерий однородности показал существенное различие между выборками значений этого признака для двух сравниваемых классов, то P_i является признаком второго вида;

– если для признака P_i не выполнилось ни одно из двух предыдущих условий, то он относится к третьему виду.

В результате только признаки второго вида $P^{(2)} = \{P_1^{(2)}, P_2^{(2)}, \dots, P_{n_2}^{(2)}\}$ включаются в словарь информативных признаков.

Отметим, что не исключена ситуация, когда этот словарь оказывается пустым. В этом случае необходимо вернуться к формированию нового варианта априорного словаря, и затем сначала повторить процедуру анализа информативности признаков.

Шаг 6. Вновь, как и на шаге 4, с помощью алгоритма кластеризации типа Forel-2 строится k кластеров и проводится анализ их содержимого. Если каждый кластер содержит в основном объекты одного класса и не превышает допустимое пороговое значение ошибочных включений объектов в кластеры, то все признаки из словаря $P^{(2)} = \{P_1^{(2)}, P_2^{(2)}, \dots, P_{n_2}^{(2)}\}$ переносятся в словарь информативных признаков.

Шаг 7. На основе классифицированной обучающей выборки и полученного словаря информативных признаков формируются эталоны классов. На этом процедура обучения заканчивается.

Заключение

При построении системы распознавания фактически реализуются две основные процедуры, первая из которых связана с обучением системы, а вторая – с принятием решения (непосредственно распознаванием). Достоверность второй процедуры напрямую зависит от качественной реализации процедуры обучения. Если на этапе обучения удастся сформировать такое рабочее признаковое пространство, в котором эталоны классов разделены и компактны, то выполнение процедуры принятия решения принципиальных затруднений не вызывает и носит чисто технический характер. В статье представлен метод реализации процедуры обучения на основе исследования информативности признаков с использованием алгоритмов кластерного анализа. Сепарирование признаков по степени их информативности на три вида, прежде всего, ориентировано на исключение признаков, искажающих образы эталонов классов. В конечном итоге происходит не только “фокусировка” образов, но и сжатие размерности пространства, что требует меньших ресурсов для выполнения процедур обучения и распознавания.

Abstract. The paper presents a method of the realization of the instruction procedure (instruction of the system) on the basis of studying self-descriptiveness of the signs with the use of cluster analysis algorithms.

Литература

1. Распознавание образов: состояние и перспективы: Пер. с англ./ К.Верхаген, Р.Дейн, Ф.Грун и др. – М.: Радио и связь, 1985. – 104 с.
2. Загоруйко Н.Г. Прикладные методы анализа данных и знаний. – Новосибирск: Издательство Института математики, 1999. – 266 с.
3. Васильев В.И. Проблема обучения распознаванию образов. – К.: Выща шк. Головное изд-во, 1989. – 64 с.
4. Родченко В.Г. Технология атрибуционных исследований на основе методов теории распознавания образов // Веснік ГрДУ. Сер. 2. – 2001. – №2(28). – С. 89 – 94.
5. Родченко В.Г. Об одном методе построения компактных эталонов классов при проектировании систем распознавания образов // Известия Гомельского государственного университета имени Ф.Скорины. – 2004. – №4(25). – С.114–117.