

УДК 004.89, 004.93

Мурыгин К.В.

Институт проблем искусственного интеллекта МОН Украины и НАН Украины,

г. Донецк

kir@iai.donetsk.ua

Комбинирование бинарных свойств в виде МКВ-классификатора

В статье рассматривается алгоритм объединения бинарных свойств, широко используемых на практике при разработке систем автоматического анализа визуальной информации, в виде МКВ-классификатора. Предложенный алгоритм позволяет генерировать более эффективные решающие правила по сравнению с известным алгоритмом AdaBoost, а также существенно сократить число используемых свойств при одинаковой классифицирующей способности, за счет более точного описания положения объектов в пространстве признаков.

Введение

Одним из способов решения задач распознавания является построение классификаторов на основе объединения простых, но недостаточно эффективных по отдельности признаков, согласно некоторому алгоритму обучения, цель которого минимизировать ошибку классификации. К таким алгоритмам относится достаточно популярный и часто используемый для решения задач распознавания зрительных образов алгоритм AdaBoost. Алгоритм AdaBoost использует подход к обучению классификации, основанный на объединении некоторого количества малоэффективных элементарных классификаторов (ЭК) в один, более качественный, на основе их линейной комбинации. Если такие классификаторы бинарные (возвращают два значения, например, 1 и 0), то для их объединения используется классический подход, предложенный Шапиро и др. [1-3]. В случае использования бинарных классификаторов положение объектов в пространстве их представления в виде возвращаемых классификаторами значений ограничивается вершинами куба, размерности, равной числу используемых классификаторов. При таком расположении объектов разделение их плоскостью является достаточно грубым, особенно если число классификаторов невелико. Для более качественного описания положения объектов в пространстве целесообразно использовать данные о расположении обучающих объектов в вершинах многомерного куба. Назовем такой классификатор – МКВ-классификатор. При таком подходе каждая из ограниченного множества вершин наделяется атрибутом принадлежности к определенному классу. При классификации объект попадает согласно принятым значениям набора элементарных классификаторов в одну из вершин куба, и относится к классу в соответствии с атрибутом данной вершины. При решении двух классовых задач распознавания достаточным является пометить вершины, принадлежащие одному из классов, а все остальные автоматически будут относиться к объектам второго класса. Последнее в полной мере относится к задаче поиска объектов, где необходима классификация объект/все остальное. Так как количество вершин очень быстро увеличивается с ростом

числа классификаторов (2^n), при бинарной классификации удобно использовать представление классификатора в виде дерева решений.

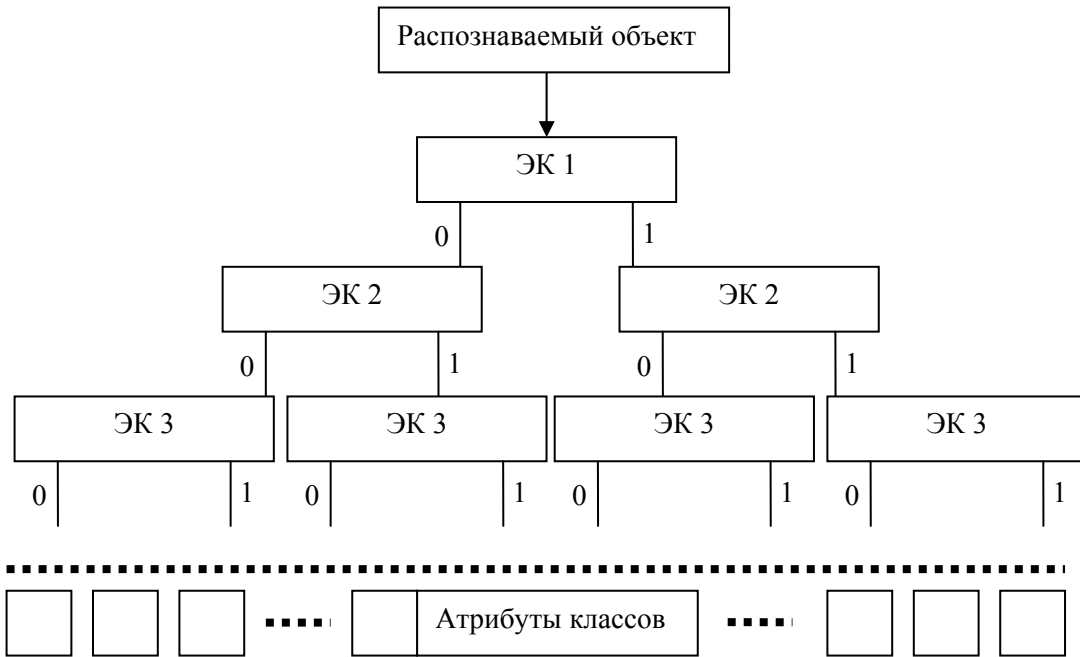


Рисунок 1 – Схема представления МКВ-классификатора, составленного из набора элементарных бинарных классификаторов, в виде дерева решений

При больших количествах используемых элементарных классификаторов число вершин многомерного куба может быть достаточно большим, однако в силу того, что число обучающих объектов, как правило, не настолько велико, то число используемых вершин ограничивается сверху объемом обучающей выборки.

Обучение МКВ-классификатора

Качественное обучение МКВ-классификатора предполагает комбинирование некоторого количества ЭК таким образом, чтобы пересечение обучающих объектов разных классов в вершинах многомерного куба было минимальным. Произвольный объект, подаваемый на вход МКВ-классификатора, согласно принятым значениям ЭК попадает в одну из вершин многомерного куба. Таким образом, имея определенный обучающий набор объектов и зная их классовую принадлежность, можно оценить частоты попадания объектов разных классов в вершины куба. Назначение атрибута классовой принадлежности вершины осуществляется путем выбора класса, которому соответствует максимальная вероятность попадания в данную вершину. Если обозначить функцию МКВ-классификатора, возвращающую атрибут класса для произвольного входного объекта \bar{x} как $h(\bar{x})$, а его истинную принадлежность (правильный атрибут) как y , то для ошибки классификации будем иметь:

$$E = \frac{1}{N} \sum_{i=1}^N S_i, \text{ где } S_i = \begin{cases} 1, h(\bar{x}_i) \neq y_i, \\ 0, \text{ иначе.} \end{cases}$$

Здесь N – число обучающих объектов. В ходе обучения ЭК выбираются таким образом, чтобы минимизировать ошибку классификации E .

Процесс комбинирования элементарных классификаторов может иметь значительную вычислительную сложность в силу необходимости решения задачи полного перебора, особенно при большом числе ЭК. Вместе с тем процесс обучения можно значительно упростить, применив по аналогии с AdaBoost последовательный отбор ЭК в ходе формирования МКВ-классификатора. Общая схема процесса обучения приведена на рис. 2.

- 1) Выбирается наилучший ЭК с точки зрения минимизации ошибки классификации.
- 2) Для каждого цикла обучения $t = 2, \dots, T$:
 - 2.1) организовывается цикл добавления ЭК к уже включенным в МКВ-классификатор;
 - 2.2) считается ошибка классификации после добавления текущего ЭК в МКВ-классификатор;
 - 2.3) выбирается ЭК, который при добавлении в МКВ-классификатор дает максимальное уменьшение ошибки, и включается в МКВ-классификатор.
- 3) После достижения требуемой ошибки классификации процесс обучения заканчивается.

Рисунок 2 – Алгоритм обучения МКВ-классификатора

Самым вычислительно сложным этапом приведенного алгоритма является оценка ошибки МКВ-классификатора с добавлением нового ЭК. Для ускорения выполнения вычислений на этом этапе удобно заполнять таблицу принятых элементарными классификаторами значений:

Таблица 1 – Принятые элементарными классификаторами значения

№ ЭК	Объект 1	Объект 2	Объект 3	Объект 4	...	Объект N
1	0	1	0	0	...	0
2	1	1	0	1	...	0
3	0	0	0	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
T-1	1	1	0	1	...	0
T - новый	0	0	1	0	...	1
Номер впервые встретившегося такого же вектора	1	2	3	1	...	3

Последняя строка таблицы содержит номер объекта, который имеет меньший или равный текущему порядковый номер в списке обучающих объектов и для которого значения всех ЭК совпадают с соответствующими значениями ЭК для текущего объекта. Она позволяет определить количество вершин куба, в которые попадают все объекты обучающего набора, и оценить частоты попадания в каждую вершину объектов каждого класса. Это позволяет назначить вершинам атрибуты классов из условия минимизации ошибок классификации.

Последняя строка позволяет быстро находить впервые встретившийся вектор в таблице, равный текущему вектору. Действительно, зная значения последней строки


без добавления очередного ЭК и значение этого ЭК для данного объекта достаточно ввести дополнительные две строки в таблицу выше:

	Объект 1	Объект 2	Объект 3	...	Объект N
Номер впервые встретившегося такого же вектора без добавления последнего ЭК	1	2	3	...	3
Номер впервые встретившегося такого же вектора при условии, что добавленный ЭК возвращает 0	1	2	10	...	28
Номер впервые встретившегося такого же вектора при условии, что добавленный ЭК возвращает 1	23	45	3	...	3

Вычисляя значение добавленного ЭК для текущего объекта и зная первый, совпадающий с ним объект в списке обучающих объектов без добавления последнего ЭК, можно получить номер впервые встретившегося такого же объекта, или назначить текущий объект первым найденным в последовательности, что и занести в одну из добавленных строк таблицы. Описанный подход позволяет вычислять ошибку классификации после добавления очередного классификатора с меньшими вычислительными затратами, близкими к выполнению аналогичной операции в алгоритме AdaBoost.

Тестирование МКВ-классификатора

Для тестирования предложенного МКВ-классификатора использовалась задача обнаружения области губ на изображении лица. В качестве ЭК использовались прямоугольные логические свойства, предложенные в [4]. В качестве области поиска рассматривалась область предварительно найденного лица, содержащая губы. Использовалась база изображений губ, произносящих различные звуки, положение которых было размечено вручную. В качестве обучающего набора изображений губ использовались вырезанные изображения областей губ из базы изображений лиц и изображения, полученные их горизонтальным зеркальным отражением, – всего 5616 изображений. Все обучающие изображения приведены к рабочему масштабу 16×16 пикселей. В качестве изображений класса «Фон» из базы изображений лиц и их горизонтальных зеркальных отражений случайным образом извлечены 5348 изображений. Всего вариантов изображений фона, содержащихся в изображениях базы изображений лиц, было около 461 000 000. Примеры изображений обучающего набора приведены на рис.3.



а)




Рисунок 3 – Примеры изображений обучающего набора:
 а) обучающие объекты класса «Губы»,
 б) обучающие объекты класса «Фон»

В процессе обучения на одном обучающем наборе изображений получены зависимости средней ошибки классификации 1 и 2 рода от числа используемых элементарных классификаторов для МКВ-классификатора и классификатора в виде линейной комбинации ЭК, полученного методом AdaBoost (рис. 4).




Рисунок 4 – Сравнительная характеристика качества классификаторов МКВ и AdaBoost по результатам обучения

Анализ полученных зависимостей показывает, что использование МКВ-классификатора по сравнению с классификатором, получаемым в результате работы алгоритма AdaBoost, позволяет существенно сократить число используемых ЭК при достижении одинаковой средней ошибки классификации, что дает возможность значительно ускорить процесс выполнения операции классификации. Для МКВ-классификатора характерна большая скорость уменьшения ошибки обучения с увеличением числа ЭК. Согласно приведенным зависимостям при использовании 25 элементарных классификаторов ошибка МКВ-классификатора приблизительно в 10 раз меньше, чем ошибка обучения алгоритма AdaBoost. Для достижения такого значения ошибки алгоритмом AdaBoost необходимо использовать комбинацию более 200 классификаторов.

Выводы

Рассмотренный в статье подход к объединению простых свойств в МКВ-классификатор позволяет проводить эффективное обучение распознаванию образов. По скорости обучения предложенный подход не уступает алгоритму обучения AdaBoost, а по эффективности получаемых решений позволяет значительно уменьшить число используемых свойств при сохранении требуемого качества классификации. Последняя особенность МКВ-классификатора, а также возможность его представления в виде дерева решений определяет высокую скорость работы классификатора, по сравнению с линейной комбинацией значений свойств, получаемой при использовании алгоритма обучения AdaBoost. Основным направлением дальнейших исследований является исследование возможностей использования описанного подхода для решения задачи обнаружения более широкого круга целевых объектов, в частности номерных знаков автомобилей, лиц людей и т.п., что позволит определить степень его инвариантности к свойствам объектов поиска.

Литература

1. Robert E. Schapire. Boosting the margin: A new explanation for the effectiveness of voting methods / Robert E. Schapire, Freund Y. Bartlett P., Lee W.S. // Of the Fourteenth International Conference on Machine Learning. – 1997.
2. Schapire R.E. Improved Boosting Algorithms Using Confidence-rated Predictions / Schapire R.E. and Singer Y. // Machine Learning. – 1999. – P. 297-336.
3. Robert E. Schapire. The boosting approach to machine learning: An overview / Robert E. Schapire // In MSRI Workshop on Nonlinear Estimation and Classification. – 2002.
4. Мурыгин К.В. Особенности реализации алгоритма AdaBoost для обнаружения объектов на изображениях / К.В. Мурыгин // Искусственный интеллект. – 2009. – № 3. – С. 573-581.

К.В. Мурыгин

Комбінування бінарних ознак у вигляді МКВ-класифікатора

У статті розглядається алгоритм об'єднання бінарних властивостей, широко використовуваних на практиці при розробці систем автоматичного аналізу візуальної інформації, у виді МКВ-класифікатора. Запропонований алгоритм дозволяє генерувати більш ефективні вирішувачі правила в порівнянні з відомим алгоритмом AdaBoost, а також істотно скоротити число використовуваних ознак при однаковій якості класифікації, за рахунок більш точного опису положення об'єктів у просторі ознак.

К.В. Мurygin

Combination of Binary Properties in the Form of the MKV-classifier

In the article the algorithm of association of the binary properties widely used in practice at system engineering of the automatic analysis of the visual information, in the form of the MKV-classifier is considered. The offered algorithm allows to generate more effective solving rules in comparison with known algorithm AdaBoost, and also it is essential to reduce number of used properties at identical classifying ability, at the expense of more exact description of position of objects in feature space.

Статья поступила в редакцию 06.01.2010.