

Вычислительная технология распознавания цветных изображений по критериям сопряженности

Р.К. Захаров, В.А. Фурсов

Самарский государственный аэрокосмический университет имени академика С.П. Королёва (национальный исследовательский университет)

В работе рассматриваются методы, алгоритмы и информационная технология распознавания цветных изображений по критериям сопряженности и с использованием разложений по базису Карунена-Лоэва, в частности, приводятся алгоритмы отбора информативных признаков по критериям сопряженности. Рассматриваются возможности применения для этих алгоритмов различных типов декомпозиции.

1. Постановка задачи

Предполагается, что имеется M изображений каждого из K объектов. Каждое изображение представляется вектором $\mathbf{x} = [x_1, x_2, \dots, x_N]^T$ размерности N , где x_1, x_2, \dots, x_N – признаки. Векторы, соответствующие изображениям одного объекта, составляют класс. Совокупность векторов признаков всех классов образует обучающую выборку. Решение задачи распознавания состоит в конструировании решающей функции $f: R^N \mapsto \{0, 1, 2, \dots, K\}$, которая каждому вектору \mathbf{x} ставит в соответствие некоторый класс. Для уменьшения числа неправильных классификаций вводится также класс с номером 0, соответствующий отказу в распознавании.

Из множества $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M\}$ векторов каждого класса составляется $N \times M$ -матрица

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M]. \quad (1)$$

Этой матрице ставятся в соответствие так называемая информационная $M \times M$ -матрица:

$$\mathbf{A} = \mathbf{X}^T \mathbf{X} \quad (2)$$

и ковариационная $N \times N$ -матрица

$$\mathbf{B} = \mathbf{X} \mathbf{X}^T. \quad (3)$$

Предполагается, что $\text{rank} \mathbf{A} = M$. Известно также, что собственные значения $\lambda_i(\mathbf{A})$, $i = \overline{1, M}$ матрицы \mathbf{A} совпадают с ненулевыми собственными значениями матрицы \mathbf{B} , а собственные векторы матрицы \mathbf{B} , соответствующие ненулевым собственным значениям, образуют ортогональный базис (разложение Карунена-Лоэва).

2. Исследуемые решающие правила

Наряду с широко известными решающими правилами, основанными на вычислении евклидовых расстояний и меры близости Махаланобиса в работе исследуются новые, развиваемые авторами, подходы. В частности, исследуются алгоритмы распознавания, основанные на использовании в качестве мер близости показателей сопряженности. Соответствующие решающие правила строятся на следующей основе. В рассмотрение вводится

так называемый показатель сопряженности с подпространством, натянутым на векторы признаков образов объектов из заданного класса:

$$R_k = \frac{\mathbf{x}^T \mathbf{X}_k [\mathbf{X}_k^T \mathbf{X}_k]^{-1} \mathbf{X}_k^T \mathbf{x}}{\mathbf{x}^T \mathbf{x}}. \quad (4)$$

Здесь \mathbf{x} – вектор признаков неизвестного образа, предъявленный для установления близости к k -му классу, а \mathbf{X}_k – $N \times M$ -матрица, составленная из векторов образов, принадлежащих k -му классу.

Наряду с указанным, в работе рассматривается также показатель сопряженности с нуль-пространством транспонированной матрицы \mathbf{X}_k , который вычисляется как

$$S_k = \frac{\mathbf{x}^T \mathbf{T}_k \mathbf{T}_k^T \mathbf{x}}{\mathbf{x}^T \mathbf{x}}. \quad (5)$$

Здесь \mathbf{T}_k – матрица, составленная из собственных векторов, соответствующих нулевым собственным значениям матрицы $\mathbf{B}_k = \mathbf{X}_k \mathbf{X}_k^T$, а \mathbf{X}_k – $N \times M$ -матрица, та же, что и в (5).

С использованием указанных показателей сопряженности в предположении, что для каждого (k -го) класса сформирована одна из следующих $N \times N$ -матриц $\mathbf{Q}^{(k)}$:

$$\mathbf{Q}_{k,R} = \mathbf{X}_k [\mathbf{X}_k^T \mathbf{X}_k]^{-1} \mathbf{X}_k^T \quad (6)$$

или

$$\mathbf{Q}_{k,S} = \mathbf{T}_k \mathbf{T}_k^T, \quad (7)$$

соответствующая решающая функция $f(\mathbf{x})$ строится следующим образом. Вектор \mathbf{x} принадлежит m -му классу, то есть $f(\mathbf{x}) = m$, $m = 1, 2, \dots, K$,

$$\text{если } R_m = \max_k R_k, \text{ где } R_k = \frac{\mathbf{x}^T \mathbf{Q}_{k,R} \mathbf{x}}{(\mathbf{x}^T \mathbf{x})}, \quad (8)$$

$$\text{либо } S_m = \min_k S_k, \text{ где } S_k = \frac{\mathbf{x}^T \mathbf{Q}_{k,S} \mathbf{x}}{(\mathbf{x}^T \mathbf{x})}. \quad (9)$$

При использовании порогового значения T_0 , решающая функция дополняется правилом

$$f(\mathbf{x}) = 0, \text{ если } R_m \leq 1 - T_0 \text{ или } S_m \geq T_0. \quad (10)$$

3. Применение к распознаванию цветных изображений.

В работе изучаются вопросы построения процедур распознавания цветных изображений с использованием решающих правил, основанных на показателях сопряженности. В частности, исследуются вопросы построения эффективных алгоритмов отбора информативных признаков по показателям сопряженности (4), (5). Один из основных вопросов, который возникает при построении процедур распознавания цветных изображений: насколько информативными оказываются компоненты, описывающие цветовые составляющие изображений.

В работе исследуется качество распознавания при различных вариантах представления многокомпонентных изображений, в т.ч. при их разложении по ортогональным базисам

(Карунена-Лозва). Для различных вариантов представлений изображений сравниваются результаты, полученные при использовании различных решающих правил. В частности, проясняется вопрос зависимости качества распознавания от типа цветных пространств, которые используются для представления дополнительных цветных компонент векторов признаков.

4. Применение к задаче кластеризации цветных изображений.

Известно, что решение о принадлежности образа классу может оказаться ошибочным в случае, если векторы одного класса обучающей выборки сильно отличаются друг от друга. Известный путь преодоления этой проблемы состоит в разбиении обучающих классов на подклассы – кластеризации. В работе исследуется эффективность применения для формирования кластеров в качестве меры близости показателей сопряженности.

Для класса представленного в обучающей выборке множеством $\{x_1, x_2, \dots, x_m\}$ векторов образов алгоритм состоит в следующей последовательности шагов: выбор двух наиболее удаленных (по косинусу угла между векторами) образа, например, x_1 и x_2 (инициализация матриц $X_1 = [x_1]$ и $X_2 = [x_2]$); произвольный выбор вектора x_i из числа оставшихся и вычисление показателя сопряженности со столбцовыми пространствами матриц X_1 и X_2 ; добавление этого вектора x_i в качестве нового столбца к матрице, соответствующей ближайшему классу. Алгоритм может применяться к каждому из полученных кластеров для дальнейшего разбиения на подклассы.

При обработке цветных изображений большое влияние на качество кластеризации также может оказывать тип цветного пространства в котором представляются изображения.

5. Задачи исследования параллельных алгоритмов

Применение расширенных матриц признаков, включающих дополнительные цветные составляющие, приводит к существенному возрастанию вычислительных затрат. Поэтому в работе исследуются различные схемы декомпозиции, для построения параллельных и распределенных алгоритмов.

Экспериментальные исследования проводятся на вычислительном кластере. Цель экспериментов состоит в проверке условий изоэффективности при различной вычислительной сложности задачи. Результатом будут рекомендации по выбору числа вычислительных узлов в зависимости от объема обучающей выборки для каждого типа решающего правила.

Литература

1. Zhao W., Chellappa R., Rosenfeld A., Phillips P.J. Face Recognition // A Literature Survey, ACM Computing Surveys, 2003. P. 399-458.
2. Turk M.A., Pentland A.P. Face Recognition Using Eigenfaces, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Maui, Hawaii, USA, 3-6 June 1991. P. 586-591.

3. Belhumeur P.N., Hespanha J.P., Kriegman D.J. Eigenfaces vs. Fisherfaces: Recognition using Class Specific Linear Projection, Proc. of the 4th European Conference on Computer Vision, ECCV'96, 15-18 April 1996, Cambridge, UK, P. 45-58.
4. Fursov V.A., Kozin N.E. Stage-wise learning of radial neural networks // Proceedings of The 12th ISPE International Conference on Concurrent Engineering: Research and Applications, Focus Symposium Recursive Dynamics and Iterated Mappings in Service Modeling and Design, Ft. Worth/Dallas, USA, 25 – 29 July, pp. 391-396.
5. Fursov V.A., Kozin N.E. Algorithm for parallel learning of radial neural networks, Proceedings of The IASTED International Conference on Automation, Control and Applications (ACIT-ACA 2005), Novosibirsk, June 20-24, Russia. 2005. P. 481-485.