

Корреляционные признаки для классификации текстурных изображений

М.А. Туркова¹, А.В. Гайдель^{1,2}

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

²Институт систем обработки изображений РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

Аннотация. Целью работы является исследование различных корреляционных характеристик изображения для решения задачи классификации текстурных изображений. В ходе работы была поставлена серия экспериментов на множестве 4480 реальных цифровых изображений из открытого набора Kylberg Texture Dataset v. 1.0. Подготовлен комплекс программ, позволяющий произвести необходимые расчеты. Вычислены автокорреляционные характеристики изображения, а также получены аппроксимирующие коэффициенты из уравнения регрессии. Доля верно распознанных изображений составила 88,7% для 28 классов изображений.

1. Введение

В настоящее время во многих областях возникает проблема распознавания и классификации изображений. На производстве ставятся задачи по определению рода дефекта по фотографиям, в медицине автоматически выделяются области больных тканей. Для классификации каждого изображения, необходимо выделить ряд признаков, по которым программа сможет отнести его к той или иной группе.

Несмотря на актуальность проблемы обработки данных, до сих пор не было найдено оптимального метода по выявлению признаков, а также по их отбору. Существующие алгоритмы имеют высокую вычислительную сложность, что делает задачу громоздкой, а исполняющую программу медленной. Поэтому вместо использования множества полного набора имеющихся признаков, следует выделить подмножество таких признаков, которые вносят наиболее значительный вклад в характеристику изображений. При удачном выборе подмножества не произойдет потери в точности при классификации, но существенно снизится время, затрачиваемое на работу программы по классификации.

В работе [1] отбор признаков осуществляют в два этапа: на первом шаге оценивается соответствие каждого признака целевой функции, если признак нерелевантный, то его отбрасывают. На втором шаге минимизируется количество признаков путем удаления повторяющихся или низкоэффективных функций. Подробнее про процесс отбора признаков и использование отсчетов корреляционной функции в качестве признаков описано в статье [2]. В работе [3] процесс отбора признаков осуществляется с помощью эвристического эволюционного алгоритма, на примере конкуренции в племени, то есть только наиболее значимые признаки побеждают и участвуют в классификации.

В настоящей работе подготавливается база и раскрывается идея метода по отбору корреляционных признаков для классификации изображений, который будет давать существенное ускорение времени работы программы без потери точности.

2. Экспериментальные исследования

В качестве базы текстурных изображений была использована Kylberg Texture Dataset v. 1.0 [4]. Каждый из 28 классов содержит по 160 уникальных монохромных фотографий размером 576×576 пикселей с математическим ожиданием равным 127 и дисперсией 40, примеры которых приведены на рисунке 1а, 1б. В работе [5] при помощи нейронных сетей на основе этой базы изображений была достигнута точность от 89,5 % до 99,2 %, в зависимости от рода используемых сетей.

Для решения задачи по отбору признаков, необходимо сначала сформировать само полное множество признаков. Для этого было решено использовать корреляционные признаки текстурных изображений, полученные по формуле (1).

$$r(m, n) = \frac{1}{(N_i - |m|)(N_j - |n|)} \sum_i \sum_j I(i, j) I(i + m, j + n) \left(\frac{1}{N_i N_j} \sum_{i=1}^{N_i} \sum_{j=1}^{N_j} I(i, j)^2 \right)^{-1}, \quad (1)$$

где $I(i, j)$ – значение пикселя и предполагается, что изображение имеет размер $N_i \times N_j$ [6]. В данном случае мы используем 25 отсчетов, варьируя m и n от 0 до 4.

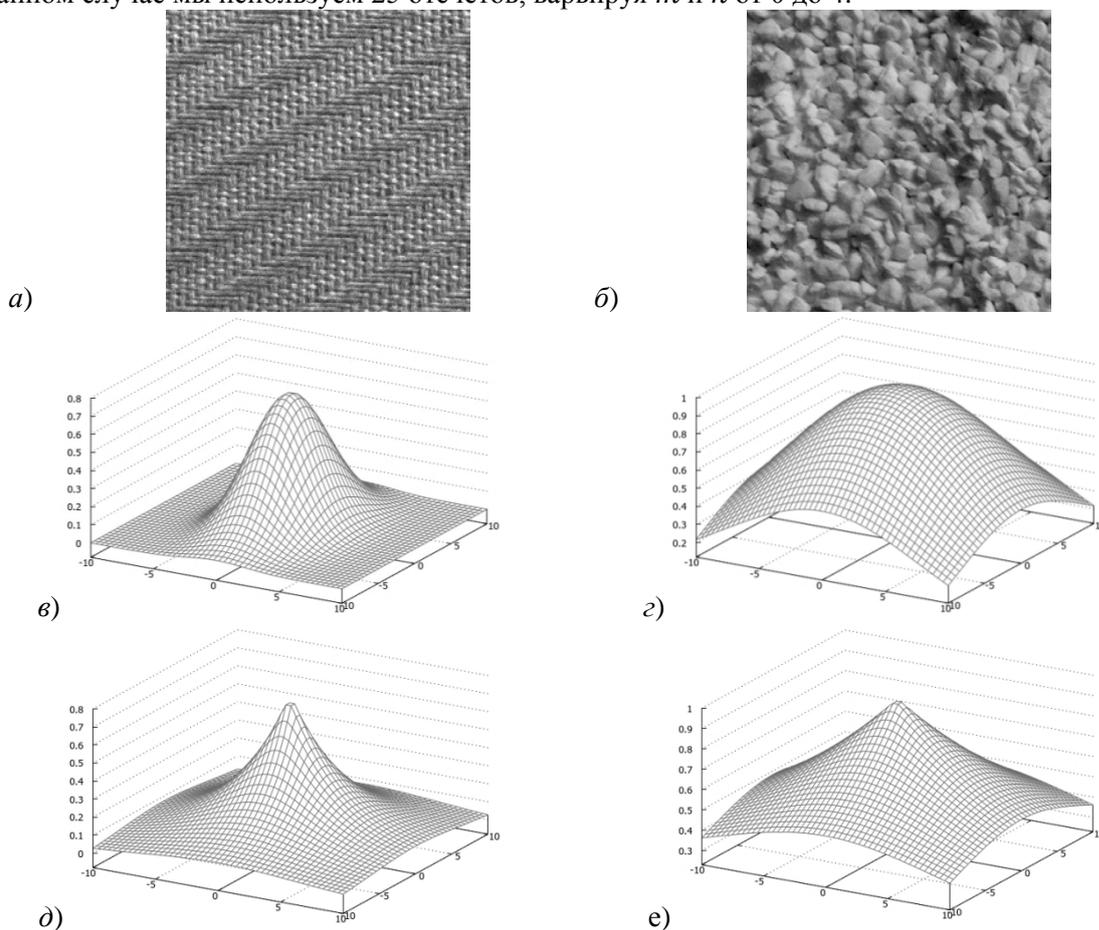


Рисунок 1. Примеры построения экспоненциальных функций с коэффициентами из уравнения регрессии: текстурное изображение сиденья (а), текстурное изображение жемчужного сахара (б), график экспоненциальной функции (2) для изображения (а) (в), график экспоненциальной функции (2) для изображения (б) (г), график экспоненциальной функции (3) для изображения (а) (д), график экспоненциальной функции (3) для изображения (б) (е).

Вторым классом признаков стали коэффициенты из уравнений регрессии (2) и (3):

$$r(m, n) = \exp(a_1 m^2 + a_2 n^2 + a_3), \quad (2)$$

$$r(m, n) = \exp(b_1(m^2 + n^2)^{1/2} + b_2). \quad (3)$$

Их выбор был обусловлен тем, что такие кривые могут достаточно точно описывать форму корреляционной функции, позволяя оценить ее значения даже точнее, чем сами отсчеты этой функции. Примерный вид функций (2) и (3) для некоторых классов текстурных изображений представлен на рисунке 1в-е.

Таким образом, для каждого изображения был сформирован вектор, состоящий из 30 признаков. Перед тем как приступить к дальнейшим действиям с полученным вектором, необходимо его нормализовать.

Приступим непосредственно к классификации изображений. Для этого необходимо сформировать обучающую выборку. В данной работе формируем ее по принципу контроля по отдельным объектам (leave-one-out cross-validation), то есть на каждом итерационном шаге обучающей является выборка из $K - 1$ элементов, где K – полный размер выборки. За счет этого мы повышаем точность классификации, которая определяется как отношение числа верно определенных классов к их общему количеству, хотя и увеличиваем вычислительную сложность алгоритма. Изображение с неизвестным классом мы распределяем в ту или иную группу по признаку ближайшего соседа, находя ближайший к искомому вектор по набору признаков.

При использовании только отсчетов корреляционной функции в качестве набора признаков достигается высокая точность классификации – 86,8 %. При выборе за множество признаков коэффициентов из (2) и (3) точность снижается до 69,8 % и 53,8 %, соответственно.

Несмотря на то, что использование корреляционных признаков дало высокие результаты, использование их неоправданно – для того, чтобы их вычислить для большого количества изображений, понадобилось несколько часов машинного времени, тогда как желательно решать задачу в режиме реального времени.

Для ускорения работы ограничим размер вектора признаков до пяти, уменьшив его в шесть раз. Необходимо перебрать все подмножества исходных векторов. Получаем 17 100 720 векторов – комбинаций признаков, точность классификации при работе с каждым из которых нужно оценить.

Получаем, что при использовании только первых пяти признаков, точность классификации составляет 83,7 %, что лишь на 5 % ниже, чем при использовании полного набора признаков, время работы программы увеличилось в 6 раз.

3. Заключение

В работе было произведено формирование наборов признаков для классификации текстурных изображений, которые включили в себя коэффициенты корреляционной функции, а также коэффициенты из уравнений регрессии. Наивысшая точность, достигнутая на основе этих признаков, составила 88,7 %.

Использование только лишь коэффициентов из уравнений регрессии оказалось менее эффективным, чем признаки, сформированные из корреляционных отсчетов. Для ускорения существующего метода необходимо из всего множества признаков выделить подмножество наиболее эффективных.

4. Благодарности

Работа выполнена при поддержке Федерального агентства научных организаций (соглашение № 007-ГЗ/ЧЗ363/26) и гранта РФФИ 16-41-630761 р_а, а также Министерства образования и науки РФ в рамках мероприятий Программы повышения конкурентоспособности Самарского университета среди ведущих мировых научно-образовательных центров на 2013-2020 годы.

5. Литература

- [1] Rahmaninia, M. OSFSMI: Online Stream Feature Selection Method based on Mutual Information / M. Rahmaninia, P. Moradi // *Applied Soft Computing Journal*. – 2017. DOI: 10.1016/j.asoc.2017.08.034.
- [2] Гайдель, А.В. Возможности текстурного анализа компьютерных томограмм в диагностике хронической обструктивной болезни / А.В. Гайдель, П.М. Зельтер, А.В. Капишников, А.Г. Храмов // *Компьютерная оптика*. – 2014. – Т. 38, № 4. – С. 843-850.
- [3] Маа, В. A tribe competition-based genetic algorithm for feature selection in pattern classification / В. Маа, Y. Xia // *Applied Soft Computing Journal*. – 2017. – Vol. 58. – P. 328-338.
- [4] Kylberg, G. The Kylberg Texture Dataset v. 1.0, Centre for Image Analysis, Swedish University of Agricultural Sciences and Uppsala University, External report (Blue series) No. 35. – URL: <http://www.cb.uu.se/~gustaf/texture/>.
- [5] Andrearczyk, V. Using Filter Banks in Convolutional Neural Networks for Texture Classification / V. Andrearczyk, P.F. Whelan // *Pattern Recognition Letters*. – 2016. – Vol. 84. – P. 63-69.
- [6] Petrou M. *Image Processing: Dealing With Texture* / M. Petrou, P.G. Sevilla, 2006. – 634 pp.

Correlative features for the classification of textural images

М.А. Туркова¹, А.В. Гайдель^{1,2}

¹Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

²Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

Abstract. The aim of our work is to study various correlative features of the images in order to solve the classification problem of textural images. In the present paper series of experiments was performed on a set of 4480 real digital images from the open Kylberg Texture Dataset v. 1.0. A set of programs which is necessary for computations was developed. The autocorrelative features of the images are calculated, and the approximating coefficients from the regression equation are obtained. The correctly recognized images made 88.7% for 28 classes of images.

Keywords: textural analysis, correlative features, image classification, linear regression, k-nearest, neighbors algorithm.