

ИНФОРМАТИКА

УДК 681.327

**АЛГОРИТМ ТЕКСТУРНОЙ КЛАСТЕРИЗАЦИИ
СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ
КОНКУРЕНТНОЙ НЕЙРОННОЙ СЕТИ**

Р.Х. САДЫХОВ, М.М. ЛУКАШЕВИЧ

*Белорусский государственный университет информатики и радиоэлектроники
П. Бровки, 6, Минск, 220013, Беларусь**Поступила в редакцию 21 сентября 2007*

Предложен алгоритм текстурной кластеризации спутниковых изображений с использованием конкурентной нейронной сети. Входными данными для кластеризации являются вычисляемые по полутоновым матрицам смежности текстурные признаки Харалика. Использование конкурентной нейронной сети позволило достичь приемлемых результатов распознавания за счет способности нейронной сети адаптироваться к входным данным.

Ключевые слова: текстура, текстурные признаки, полутоновая матрица смежности, кластеризация, искусственная нейронная сеть.

Введение

В настоящее время все большее значение в дистанционном зондировании (ДЗ) Земли приобретает информация, полученная из космоса, основу которой составляют спутниковые изображения. Данный метод исследований является базовым в сфере стремительно развивающихся геоинформационных технологий. Проблемы ДЗ тесно связаны с цифровой обработкой изображений. Основной задачей при этом является выделение объектов. Одним из самых распространенных методов выделения объектов на спутниковых изображениях является кластеризация. При решении данной задачи используют различные подходы, в том числе и текстурный анализ изображений [1–3].

Наиболее ранние результаты исследований, лежащих в основе механизмов компьютерного зрения, были проведены [4, 5]. Тогда было сделано предположение о том, что текстура может быть распознана и дифференцирована только через статистические данные первого и второго порядка. Позже в [6] была доказана ошибочность этого предположения, что способствовало дальнейшим успехам в текстурном анализе — фактически развитию отдельной области анализа изображений и компьютерного зрения.

Статистические методы текстурного анализа наилучшим образом подходят для прикладных дистанционных исследований в силу случайного характера природных процессов [3]. Детальный аналитический обзор ранних исследований в текстурном анализе представлен в [7], где описаны зависимости характеристик текстуры, статистический и структурный подходы. Статистические методы получают текстурные признаки с использованием ряда математических инструментов таких, как автокорреляционная функция, дискретные преобразования (Фурье, Адамара), градиентная информация, морфология, полутоновые матрицы, модели полутоновых пространственных зависимостей и

авторегрессионные модели. Многие из этих подходов позднее были разработаны, получили более строгое описание [1, 2], исследуются и получают дальнейшее развитие и в настоящее время, так как дают устойчиво хорошие результаты.

Общие теоретические сведения

Полутоновые матрицы смежности. Среди статистических методов наибольший интерес представляет метод текстурного анализа, предложенный Хараликом Р.М., который использует полутоновые матрицы смежности (gray level co-occurrence matrices, GLCM) [8–11].

Полутоновые матрицы смежности для изображения представляют собой оценку плотности распределения вероятностей второго порядка $p_2(P, Q, Z, Y)$, полученную по одному изображению в предположении, что плотность вероятности p_2 зависит лишь от взаимного расположения P и Q . Z — число, обозначающее учет каких соседних пикселей происходит, на каком расстоянии от пикселя интереса они находятся. Y — значение ориентации пикселя интереса и соседних пикселей — $0^\circ, 45^\circ, 90^\circ, 135^\circ$. Иными словами можно сказать, что матрица GLCM строится на основе вычислений того, как часто пиксель со значением интенсивности i встречается с пикселем со значением интенсивности j . Каждый элемент (i, j) в матрице смежности описывает число случаев, когда пиксель со значением i встречается с пикселем со значением j .

Матрицы смежности представляют собой свойства текстуры, но они не удобны для непосредственного применения при анализе изображения, например, для сравнения двух текстур. Вместе с тем матрицы смежности используются для вычисления характерных признаков, которые могут служить более компактным представлением текстуры. На основе матрицы смежности можно вычислить 14 текстурных признаков Харалика Р.М. В качестве наиболее информативных текстурных признаков по Харалику можно выделить следующие, которые широко используются в текстурном анализе [7, 12–16].

1. Второй угловой момент

$$f_1 = \sum_i \sum_j A(i, j)^2 \quad (1)$$

2. Контраст

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{\substack{i=1 \\ |i-j|=n}}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right\} \quad (2)$$

3. Корреляция

$$f_3 = \frac{\sum_i \sum_j (i, j) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

4. Обратный момент разностей

$$f_5 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j) \quad (4)$$

Конкурентная нейронная сеть. Одним из направлений совершенствования методов обработки данных ДЗ является использование искусственных нейронных сетей (ИНС), обладающих способностью реализовать широкий класс функций без априорных допущений о законах их распределения [16, 17]. Разработка эффективных алгоритмов, основанных на искусственных нейронных сетях, для решения задач подобного класса представляется актуальной и имеет широкий спектр приложений. Предварительное исследование

возможностей различных типов нейронных сетей показало, что наиболее оптимальными для тематической обработки ДЗ являются конкурентные нейронные сети Кохонена, которые не только позволяют корректировать обработку на любом этапе, но и не требуют обязательного для большинства типов нейронных сетей этапа первоначального обучения.

Самоорганизующаяся конкурентная нейронная сеть обучается без учителя; она способна адаптироваться к входным данным, используя содержащиеся в этих данных зависимости. Топология сети представлена на рис. 1.




Рис. 1. Конкурентная нейронная сеть

Первый слой является распределительным, а нейроны второго уровня функционируют в соответствии с соотношением

$$y_j = \sum_{i=1}^n w_{ij} x_i = |w^j| |x| \cos \alpha, \quad (5)$$

где $x = (x_1, x_2, \dots, x_i, \dots, x_n)$ — входной вектор; $w^j = (w_{1j}, w_{2j}, \dots, w_{ij}, \dots, w_{nj})$ — вектор весовых коэффициентов нейрона; $|x|$ и $|w|$ — их модули; α — угол между ними.

Алгоритм текстурной кластеризации

В алгоритме текстурной кластеризации, представленном в данной статье, авторы попытались совместить достоинства выбора текстурных признаков Харалика и преимущества конкурентной нейронной сети, используемой на этапе кластеризации.

В представленном алгоритме можно выделить следующие этапы (рис. 2.)

1 Этап. Расчет текстурных признаков эталонных областей. Первоначально выбирается количество кластеров, затем произвольно выделяются области на изображении с однородной текстурой. Количество выбираемых областей больше или равно количеству кластеров. Для каждой из выбранных областей вычисляются полутоновые матрицы смежности и текстурные признаки Харалика.

2 Этап. Настройка и обучение конкурентной нейронной сети. В соответствии с количеством кластеров и используемых текстурных признаков производится настройка нейронов в распределительном и выходном слоях нейронной сети. Количество нейронов в распределительном слое будет соответствовать количеству рассчитываемых текстурных признаков, а количество нейронов в выходном слое будет равно числу кластеров, заданных на первом этапе.



Рис. 2. Основные этапы алгоритма текстурной кластеризации

В качестве алгоритма обучения нейронной сети было выбрано частотно-зависимое конкурентное обучение. Согласно нему, нейрон-победитель определяется по минимуму произведения евклидова расстояния между входным и весовым вектором и количеством побед данного нейрона f_i .

$$d_v = \min(|x - w^j| f_i). \quad (6)$$

Шансы нейрона на победу уменьшаются с количеством побед, что дает преимущество другим нейронам. Конкурентное обучение продолжается до тех пор, пока максимум евклидова расстояния между любым входным вектором и соответствующем ему вектором весов нейрона-победителя не достигнет заданного малого значения, которое определялось экспериментальным путем.

Конкурентная сеть позволяет разбить входную выборку нормированных векторов на m (количество выходных нейронов сети) кластеров, расположенных на поверхности гиперсферы в пространстве признаков единичного радиуса. Входные векторы, приводящие к победе одного и того же нейрона, относят к одному кластеру. На рис. 3 представлена блок-схема алгоритма настройки и обучения конкурентной нейронной сети.

3 Этап. Поблочная кластеризация рассчитанных текстурных признаков. Все изображение разбивается на блоки. Эксперименты показали, что минимально возможный размер блоков для этого алгоритма 3×3 пикселя. Для каждого из блоков производится вычисление полутоновых матриц смежности и текстурных признаков Харалика. Полученные вектора признаков для каждого блока подаются на вход конкурентной нейронной сети, которая относит каждый из блоков в определенному кластеру.

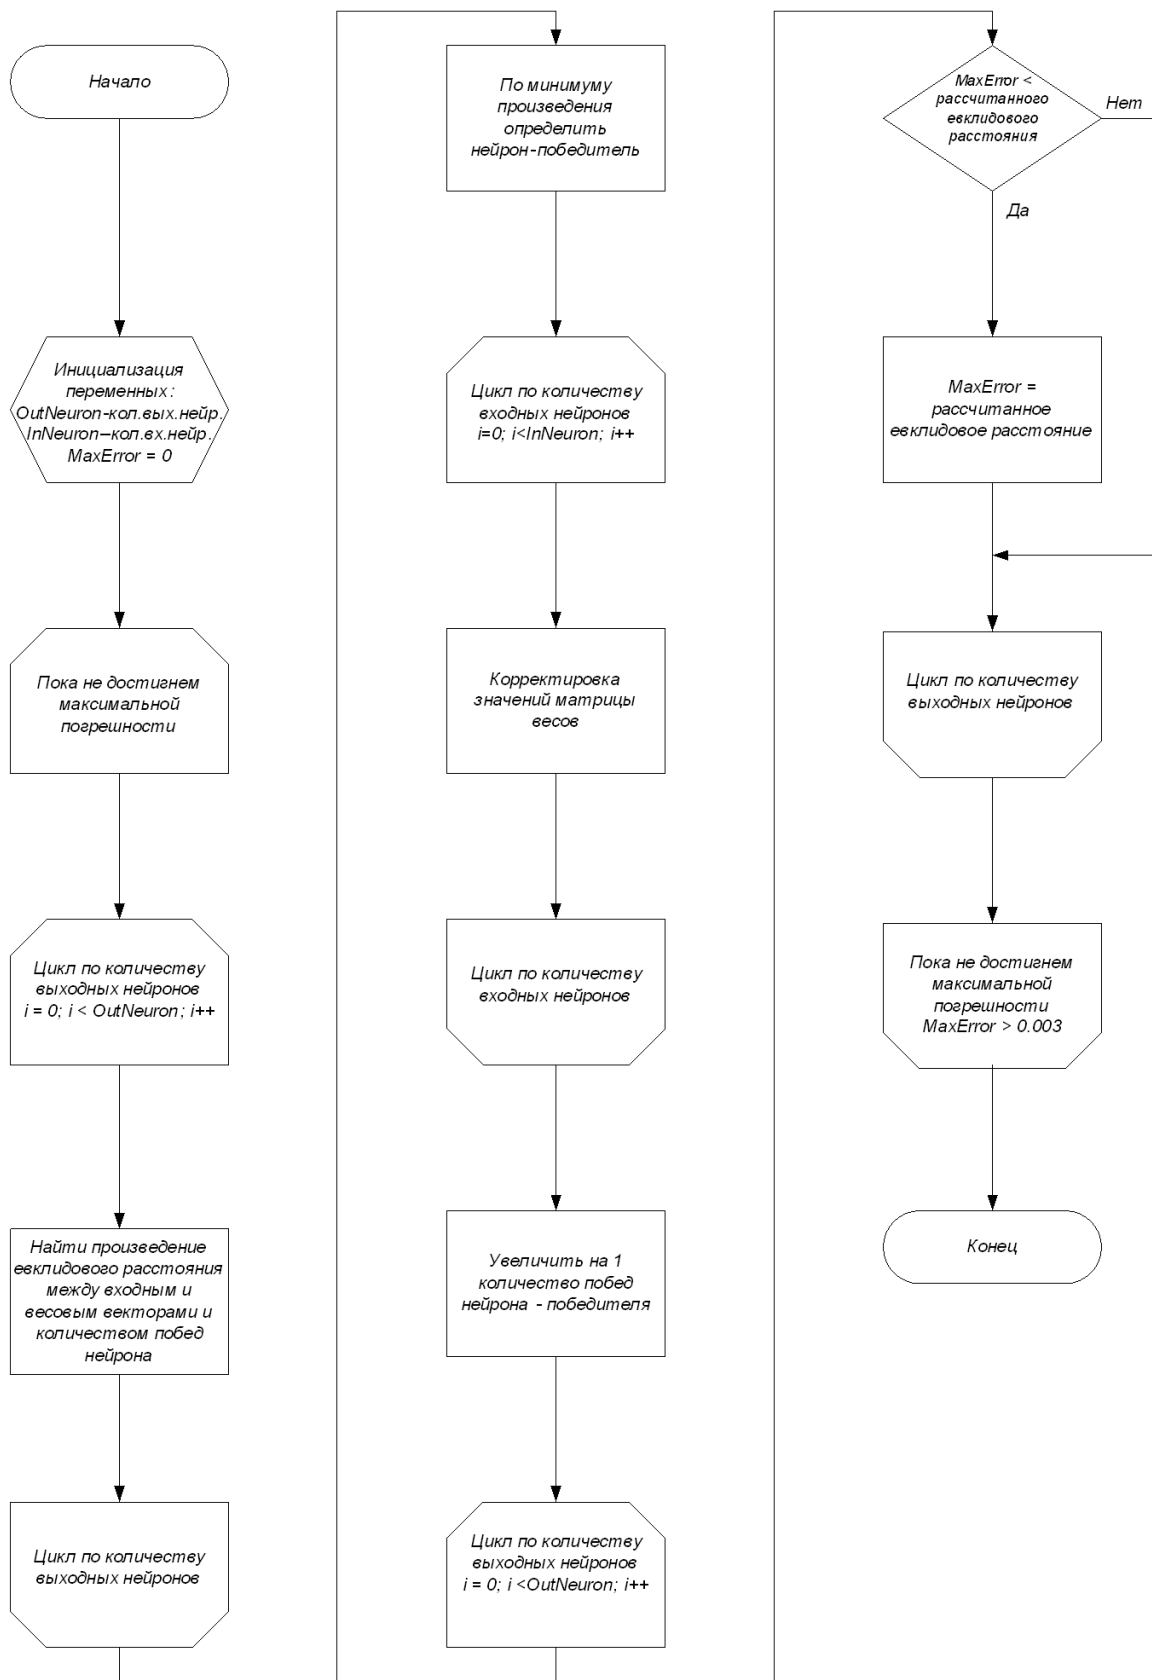


Рис. 3. Блок-схема алгоритма настройки и обучения конкурентной нейронной сети

Результаты экспериментов

Предложенный в данной статье алгоритм был реализован в программном модуле, позволяющем вычислить 14 текстурных признаков Харалика и произвести кластеризацию изображения.

Тестирование алгоритма проводилось на базе текстур Brodatz и спектрональных снимках земной поверхности спутника Landsat 7 ETM+.

На рис. 4. представлены результаты кластеризации спутникового изображения (3 кластера) по 14 текстурным признакам Харалика.




Рис. 4. Результаты кластеризации спутникового изображения

Результаты показали эффективность применения конкурентной нейронной сети для кластеризации изображения с использованием текстурных признаков Харалика. Эксперименты доказали, что достоверность распознавания данного алгоритма на базе текстур Brodatz составляет порядка 87%, что выше результатов распознавания, приведенных в [18], что достигнуто за счет хорошей адаптации конкурентной нейронной сети к входным данным.

Заключение

В статье предложен алгоритм текстурной кластеризации, отличающийся применением конкурентной нейронной сети на этапе кластеризации текстурных признаков, что позволило достичь хороших результатов распознавания (87%).

ALGORITHM OF TEXTURE CLUSTERING OF SATELLITE IMAGES USING COMPETITIVE NEURON NETWORK

R.KH. SADYKHOV, M.M. LUKASHEVICH

Abstract

The algorithm of texture clustering of satellite images using competitive neural network is offered. Entrance information for clustering is calculated on gray level co-occurrence matrices texture features of Haralick. The use of competitive neural network allowed attaining the acceptable results of recognition due to ability of neural network to adapt itself to entrance information.

Литература

1. Tuceryan M., Jain A.K. Texture Analysis. The handbook of Pattern Recognition and Computer Vision (2nd Edition) / C.H. Chen, L.F. Pau, P.S.P. Wang (eds) // World Scientific Publishing Co. 1998. P. 207–248.

2. *Materka A., Strzelecki M.* Texture Analysis Methods — A Review. Technical University of Lodz, Institute of Electronics, COST B11 report, Brussels. 1998.
3. *Martin D.R., Fowlkes C.C., Malik J.* // IEEE Transactions on Pattern Analysis and Machine Intelligence. May 2004. Vol. 26. № 5. P. 530–549.
4. *Julez B.* // RE Trans. on Information Theory. 1962. Vol. 232. P. 84–92.
5. *Julez B.* Experiments in the visual perception of texture," Sci. Amer. Apr. 1975. P. 34–43.
6. *Gagalowicz A., Ma S.* // Comput. Graphics and Image Proc. 1985. Vol. 30. P. 289–315.
7. *Haralick R.M.* // Proc. of the IEEE. May 1979. Vol. 67. № 5 P. 786–804.
8. Дистанционное зондирование: количественный подход / Ш.М. Дейвис, Д.А. Ландгребе, Т.Л. Филлипс и др. Под ред. Ф. Свейна и Ш. Дейвиса. Пер. с англ. М., 1983.
9. *Li C.-T., Chiao R.* // Image and Vision Computing. 2003. Vol. 21. P. 955–966.
10. Компьютерное зрение / Л. Шапиро, Дж. Стокман; Пер. с англ. М., 2006. 752 с.
11. *Zhang J., Tan T.* // Pattern Recognition — The Intern. J. of Pattern Recognition Soc. 2002. Vol. 35. P. 735–747.
12. *Haralick R.M., Shanmugam K., Dinstein I.* // IEEE Trans. on Systems, Man and Cybernetics. 1973. No. 6. P. 610–621.
13. *Davis L., Johns S., Aggarwal J.K.* // Proc. of 1978 IEEE Conference on Pattern Recognition and Image Processing. P. 313–318. Chicago, IL, May 1978.
14. *Zucker, S.W., Terzopoulos D.* // Comput. Graphics and Image Proc. 1980. Vol. 2. P. 286–308.
15. *Trivedi M.M.* // Comput. Vision, Graphics, and Image Proc. 1984. Vol. 28. P. 199–219.
16. *İşcan Z., Kurnaz M.N., Dokur Z., Ölmez T.* // Neural Information Processing — Letters and Reviews. Aug.–Sept. 2006. Vol. 10. P. 8–9.
17. Возможности тематического дешифрирования ДДЗ с использованием искусственных нейронных сетей [Электронный ресурс]. — Электронные данные. — Режим доступа: <http://www.geocities.com/blinkova/art2.html>.
18. *Wagner T.* Texture Analysis // Handbook of Computer Vision and Applications. 1999. Vol. 2. Chapter 12. P. 276–308.