

УДК 004.932.2

РАСПОЗНАВАНИЕ ПРИРОДНЫХ ОБЪЕКТОВ НА АЭРОФОТОСНИМКАХ С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ

М. Н. Фаворская, Н. Ю. Петухов

*Государственное образовательное учреждение высшего профессионального образования
«Сибирский государственный аэрокосмический университет
им. академика М. Ф. Решетнёва»,
660014, г. Красноярск, просп. им. газ. «Красноярский рабочий», 31
E-mail: favorskaya@sibsa.ru
n_petukhov@sibsa.ru*

Представлен метод распознавания природных объектов на аэрофотоснимках, основанный на двухуровневой процедуре сегментации, комплексном расчёте статистических и фрактальных показателей, а также использовании искусственных нейронных сетей для определения категории природного объекта, а затем типа объекта в установленной категории. Такой метод эффективен для распознавания пород деревьев на аэрофотоснимках. Приведены базовые формулы расчёта признаков природных текстур, обоснована топология применяемых искусственных нейронных сетей.

Ключевые слова: распознавание ландшафтных изображений, фрактальные показатели, искусственные нейронные сети.

Введение. Распознавание изображений природных объектов, как правило, сводится к распознаванию текстур. Известны подходы к нахождению признаков текстур, основанные на структурном, спектральном и статистическом анализе, а также на моделях. Структурный подход, использующий теорию формальных языков и методы математической морфологии, спектральный подход на базе преобразования Фурье и вейвлет-преобразования не являются эффективными для анализа природных текстур. При статистическом подходе вычисляются статистические показатели второго порядка и производные от этих показателей. Подход, основанный на моделях, использует фрактальные, скрытые марковские и параметрические порождающие модели. Именно два последних подхода наиболее целесообразны для анализа изображений природных текстур [1]. Гибридный подход, осуществляющий поиск статистических признаков второго порядка совместно с фрактальными показателями, дал достаточно интересные результаты [2]. Поскольку точность вычисления признаков напрямую зависит от объёма статистической выборки, встаёт вопрос о выборе размеров анализируемой области на цифровом изображении, которая гарантированно относилась бы только к одному природному объекту. Поэтому задача распознавания таких объектов тесно связана с задачей сегментации. В силу вариативности изображений природных объектов одним из самых эффективных методов их распознавания является применение искусственных нейронных сетей (ИНС) [3].

Предлагаемый в данной работе метод основан на комплексном расчёте статистических и фрактальных показателей и двухуровневой сегментации аэрофотоснимка с последующей классификацией с помощью ИНС изображений природных объектов не только по категориям (лесная растительность, облака, ландшафтная поверхность), но и по типам в категориях, что особенно актуально для распознавания объектов лесной растительности

(породы деревьев, кустарников) в целях мониторинга состояния участков леса. Дополнительные данные лазерной локации позволяют получить информацию о геометрических размерах крон деревьев для косвенной оценки технологической пригодности древостоя [4].

1. Сегментация аэрофотоснимка с изображением лесной растительности выполняется в виде итерационной процедуры — предварительной сегментации в целях выявления локальных статистически однородных текстурных областей и окончательной сегментации, уточняющей границы между объектами.

1.1. *Предварительная сегментация аэрофотоснимка* требуется для получения априорной информации о характеристиках областей, определения количества значимых областей на изображении и координат «центров» областей и проводить её целесообразно на основе пирамиды изображений. Стратегия анализа, состоящая в постепенном переходе от грубого просмотра к точному рассмотрению, целесообразна для нахождения центров крупных текстурных областей. При «выращивании» областей вычисляется характеристический вектор, содержащий цветные дескрипторы и дисперсию локальной области пикселя на верхнем уровне пирамиды. Затем эти дескрипторы уточняются и используются для отнесения соседних пикселей к той или иной области. Если в результате вычислений обнаруживаются новые кластеры, то пиксели, близкие по своим свойствам и расположенные в центрах таких кластеров, выбираются в качестве центров областей. Выбор критериев сходства локальных областей зависит от глобальных значений цветности анализируемого аэрофотоснимка, текстурных дескрипторов и связности пикселей. Критерий останова выращивания областей не играет определяющей роли на данном этапе.

1.2. *Окончательная сегментация.* Если известно, что на аэрофотоснимке изображены деревья, то целесообразно принять гипотезу об образовании кронами деревьев компактных областей. Тогда стратегия сегментации должна заключаться в выполнении расчётов локальных текстурных характеристик по лучам, исходящим из найденных центров областей. Места существенного изменения показателей будут свидетельствовать о границе между ними. Причём ширина границы будет не больше размера локальной области, в которой вычисляются показатели. При необходимости окончательное уточнение границ можно выполнить, анализируя простейшие характеристики пикселей (цветность, яркость) в приграничных областях с учётом связности пикселей и запрета на образование новых областей сегментации по алгоритму Зонга — Суня [5].

2. Комплексный расчёт статистических и фрактальных признаков. Поскольку изображения природных объектов обладают ярко выраженными статистическими свойствами, наибольший вклад в характерные признаки вносят статистические и фрактальные показатели.

2.1. *Вычисление статистических признаков.* Статистические признаки определяются по гистограмме яркости локальной области изображения с текстурой одного типа. Они характеризуют текстуру как гладкую, грубую, зернистую. Пусть z — случайная величина, обозначающая яркость элементов изображения, а $p(z_i)$, $i = 0, 1, 2, \dots, Q - 1$, — её гистограмма, где Q — число уровней яркости. Приведём формулы для вычисления основных статистических характеристик: средней яркости, дисперсии, нормированной дисперсии, гладкости, третьего момента, однородности, энтропии соответственно:

$$\bar{B} = \sum_{i=0}^{Q-1} p(z_i) / (Q - 1), \quad (1)$$

$$\sigma^2(z) = \mu_2(z) = \sum_{i=0}^{Q-1} \left(z_i - \sum_{i=0}^{Q-1} z_i p(z_i) \right)^2 p(z_i), \quad (2)$$

$$\sigma_{nr}^2(z) = \sum_{i=0}^{Q-1} \left(z_i - \sum_{i=0}^{Q-1} z_i p(z_i) \right)^2 p(z_i) / (Q-1)^2, \quad (3)$$

$$R = 1 - 1/(1 + \sigma^2(z)), \quad (4)$$

$$\mu_3(z) = \sum_{i=0}^{Q-1} \left(z_i - \sum_{i=0}^{Q-1} z_i p(z_i) \right)^3 p(z_i), \quad (5)$$

$$S = \sum_{i=0}^{Q-1} p^2(z_i), \quad (6)$$

$$E = \sum_{i=0}^{Q-1} p(z_i) \log_2 p(z_i). \quad (7)$$

Дисперсия является мерой яркостного контраста и служит для построения дескрипторов относительной гладкости $R \in [0, 1]$, $R = 0$ для областей постоянной яркости. Поскольку для полутоновых изображений с уровнями яркости от 0 до 255 значения дисперсии $\sigma^2(z)$ оказываются большими, дисперсия нормируется в интервале $[0, 1]$. Максимальное значение однородности S достигается для изображения, все элементы которого имеют одинаковую яркость, и уменьшается по мере роста яркостных различий. Энтропия E характеризует изменчивость яркости изображения: она, наоборот, равна 0 для области постоянной яркости и максимальна в случае равновероятных значений.

Однако статистические характеристики (1)–(7), вычисленные только на основании гистограммы, имеют ограничение, поскольку не несут информации о взаимном расположении пикселей. Один из способов учёта такой информации состоит в том, чтобы дополнительно рассматривать местоположение пикселей с близкими значениями яркости.

2.2. Вычисление фрактальных признаков. Известно, что большинство естественных поверхностей является пространственно изотропными фракталами. Считается, что связанная область A в топологическом n -пространстве самоподобна, если она есть объединение N отдельных неперекрывающихся самоподобных копий, каждая из которых уменьшена на коэффициент r по всем осям координат. Фрактальная размерность D области A выражается соотношением

$$D = \log N / \log(1/r). \quad (8)$$

Обычно естественные фрактальные поверхности проявляют статистическое самоподобие, при этом фрактальная размерность функций, описывающих такие поверхности, также задаётся выражением (8). Однако не всегда возможно определить размерность фрактального изображения с помощью характеристики самоподобия. Целесообразнее вычислять меру области A на некотором множестве R^n . Предположим, что область A можно покрыть n -мерным кубом размером L_{\max} . Если область A является уменьшенной копией с коэффициентом r , то существует $N = r^{-D}$ подобластей. Поэтому число кубов размером $L = rL_{\max}$, необходимых для покрытия всей области, вычисляется из выражения

$$N(L) = 1/r^D = [L_{\max}/L]^D. \quad (9)$$

Одним из простых способов нахождения величины фрактальной размерности D в соответствии с соотношением (9) является покрытие пространства размерностью n сеткой из кубов с длиной стороны L и подсчёт количества непустых кубов. Вычисление параметра $N(L)$ для нескольких значений L позволяет определить размерность D по наклону линии, проходящей через последовательность заполненных ячеек наименьшего размера, расположенных вдоль линии $\{\log L; -\log N(L)\}$. Другие способы расчёта фрактальной размерности, основанные на вероятностном подходе и методе покрытия поверхности эталонами, представлены в работе [6].

Однако различные фрактальные образования с одинаковой размерностью могут иметь резко различающуюся текстуру. В работе [7] был введён термин «заполнение» или «лакунарность» Λ для описания характеристик фракталов, имеющих одинаковые фрактальные размерности, но различный внешний вид или текстурные показатели. Самый известный способ определения заполнения Λ следующий:

$$\Lambda = \left\langle (M/\langle M \rangle - 1)^2 \right\rangle, \quad (10)$$

где M — масса фрактального образования; $\langle M \rangle$ — ожидаемая масса. Заполнение мало для плотной текстуры и велико для крупнозернистой. Признак заполнения, вычисляемый по формуле (10), свойствен для больших по площади текстур, но не обеспечивает адекватного различения в случае небольших сегментов изображения. В работе [6] предложен метод нахождения лакунарности для небольших сегментов.

3. Распознавание текстур природных объектов. 3.1. *Выбор топологии нейронной сети.* Наиболее перспективным методом проектирования является разработка инвариантных ИНС, построенных на структурной инвариантности, инвариантности к обучающей выборке и инвариантных признаках. Последний подход наиболее целесообразен, поскольку мы можем влиять на процесс извлечения признаков, строя инвариантные текстурные фильтры.

В наших экспериментах использовалась ИНС прямого распространения. В процессе обучения выходной сигнал $y_k(n)$ (примем, что он является единственным выходом ИНС) сравнивается с эталонным $d_k(n)$, в результате чего получаем сигнал ошибки

$$e_k(n) = d_k(n) - y_k(n),$$

где n — номер шага итеративного процесса настройки синаптических весов нейрона k .

Далее сигнал ошибки инициирует последовательность корректировок синаптических весов нейрона k . Цель достигается за счёт минимизации функции стоимости:

$$E(n) = e_k^2(n)/2.$$

Пошаговая корректировка синаптических весов нейрона k продолжается до тех пор, пока ИНС не достигнет устойчивого состояния. Минимизация функции стоимости $E(n)$ выполняется по правилу Видроу — Хоффа [3].

3.2. *Распознавание категорий объектов.* ИНС для распознавания природных текстур состоит из двух скрытых слоёв (входного и выходного) по восемь нейронов в каждом; сеть является полносвязной. На входы подаются нормированные значения фрактальной размерности (выражение (8)) и шести статистических характеристик (выражения (1), (3)–(7)), на выходе получаем тип текстуры. Результаты расчёта значения фрактальной размерности и статистические характеристики пяти природных текстур приведены в табл. 1. Нейронная сеть построена и обучена с помощью программы Neural Network Wizard 1.7. Тестовая выборка включала 350 образцов каждого вида текстуры, количество эпох (циклов) обучения

Таблица 1

Текстура	Фрактальная размерность	Среднее значение	Дисперсия	Гладкость	Третий момент	Однородность	Энтропия
Трава	2,627100	113,708	46,833	0,03714	-0,08852	0,00845	5,02285
Вода	2,603681	103,986	37,623	0,02342	0,41271	0,01024	4,82232
Кора	2,721743	105,639	46,613	0,03326	0,12975	0,00653	5,17055
Дерево	2,697814	128,925	30,332	0,01704	-0,20005	0,01407	4,58152
Куст	2,658424	114,430	49,221	0,03736	0,00422	0,00689	5,14878

Таблица 2

Текстура	Фрактальная размерность	Дисперсия	Гладкость	Третий момент	Однородность	Энтропия
Сосна	2,9263	52,30	0,0404	-0,9368	0,1433	3,807
Ель	2,9451	53,98	0,0429	-1,2700	0,1610	3,726
Берёза	2,8704	48,16	0,0372	-1,0364	0,1646	3,656
Осина	2,8642	48,04	0,0371	-0,8479	0,1183	3,908

составило 50000. Использование в скрытых слоях по 10 и 12 нейронов не даёт заметного повышения вероятности распознавания, однако несколько увеличивает время обучения ИНС.

3.3. *Распознавание типов объектов* (на примере пород деревьев сосна, ель, берёза, осина) проводилось по аналогичной процедуре. Результаты расчёта фрактальной размерности и статистических характеристик четырёх видов деревьев приведены в табл. 2. Значения средней яркости отличаются столь незначительно, что не могут считаться важным признаком, как и G-компонента (в пространстве RGB), претерпевающая сезонные изменения. ИНС также имеет два скрытых слоя, в которых используется по восемь нейронов. В режиме обучения на входы нейронной сети подавалось по 350 изображений каждой породы дерева, количество эпох обучения составило 50000.

4. Экспериментальные исследования. Разработанный в среде программирования Code Gear C++ Builder 2007 программный комплекс Texture Features v.1.0 выполняет

Таблица 3

Тип природного объекта	ИНС с 8 нейронами в каждом скрытом слое		ИНС с 10 нейронами в каждом скрытом слое		ИНС с 12 нейронами в каждом скрытом слое	
	Вероятность распознавания, %	Ложное срабатывание, %	Вероятность распознавания, %	Ложное срабатывание, %	Вероятность распознавания, %	Ложное срабатывание, %
Трава	75,3	24,7	77,8	22,2	76,3	23,7
Вода	86,7	13,3	90,3	9,7	87,9	12,1
Кора	90,1	9,9	93,2	6,8	93,7	6,3
Дерево	88,3	11,7	92,1	7,9	92,3	7,7
Куст	76,4	23,6	80,3	19,7	81,4	18,6

Таблица 4

Порода дерева	Вероятность распознавания, %	Ложное срабатывание, %
Сосна	66,2	33,8
Ель	69,4	30,6
Берёза	70,2	29,8
Осина	72,3	27,7

расчёт характеристик и включает главный модуль Main.cpp, модули расчёта статистических характеристик Stat.cpp, расчёта фрактальных показателей Fract.cpp, вспомогательных функций ImageCol.cpp. Тестирование проводилось на персональном компьютере, имеющем следующую конфигурацию: процессор Intel Core 2 Duo 2,26 ГГц; ОЗУ 2024 Мбайт; видеокарта ATI Radeon HD 3470 512 Мбайт. Результаты распознавания природных объектов и пород деревьев представлены в табл. 3 и 4 соответственно. Из табл. 3 видно, что вероятность распознавания текстур трёхслойной ИНС составляет от 76 до 93 %, а ложное срабатывание наблюдалось в 7–24 % случаев. В ходе экспериментов было обнаружено, что некоторые фрактальные образования имеют почти одинаковую размерность, для чего рассчитывался показатель лакунарности. Вероятность распознавания пород деревьев (см. табл. 4) невысока и составляет от 66 до 72 %. Это связано с тем, что признаки изображений лиственной массы имеют близкие значения (см. табл. 2). Повышения вероятности распознавания можно добиться путём обучения ИНС на большем количестве образцов, используя априорные сведения о породах деревьев, произрастающих в конкретной местности, а также данные лазерного сканирования, содержащие информацию о форме крон деревьев.

Заключение. В данной работе представлены оценки фрактальных и статистических показателей изображений природных текстур. Расчёт показателей текстур ландшафтных изображений производился с помощью программного комплекса Texture Features v.1.0, разработанного для ООО «Альтекс Геоматика» (Москва). Проведены эксперименты по выбору топологии ИНС. Показано, что вероятность распознавания изображений природных объектов с помощью трёхслойной ИНС прямого распространения, содержащей по восемь нейронов в двух скрытых слоях, достигает 93 %. Также выяснено, что вероятность распознавания пород деревьев невысока и составляет от 66 до 72 %. Требуется дополнительные меры по повышению вероятности распознавания пород деревьев.

СПИСОК ЛИТЕРАТУРЫ

1. **Потапов А. А., Пахомов А. А., Никитин С. А., Гуляев Ю. В.** Новейшие методы обработки изображений. М.: Физматлит, 2008. 496 с.
2. **Favorskaya M. N., Petukhov N. Y., Danilin I. M., Danilin A. I.** Recognition of forest textures on airphotos // Proc. of the IASTED Intern. Conf. on Automation, Control, and Information Technology (ACIT'2010). Anaheim — Calgary — Zurich: ACTA Press, 2010. Vol. 691. P. 9–14.
3. **Haykin S.** Neural networks — A comprehensive foundation. Upper Saddle River: Prentice Hall, 2005. 823 p.
4. **Favorskaya M., Zotin A., Danilin I., Smolentseva S.** Realistic 3D-modeling of forest growth with natural effect // Proc. of the Second KES International Symposium IDT 2010. Berlin — Heidelberg: Springer-Verlag, 2010. P. 191–199.

5. **Zhang T. Y., Suen C. Y.** A fast parallel algorithm for thinning digital patterns // Commun. ACM. 1984. **27**, N 5. P. 236–239.
6. **Фаворская М. Н., Петухов Н. Ю.** Комплексный расчёт характеристик ландшафтных изображений // Оптический журнал. 2010. **77**, № 8. С. 54–60.
7. **Mandelbrot B. B.** The fractal geometry of nature. N. Y.: Freeman, 1982. 480 p.

Поступила в редакцию 15 февраля 2011 г.
