

УДК 528.85 : 517.44

ИССЛЕДОВАНИЕ ЗАВИСИМОСТИ РЕЗУЛЬТАТОВ КЛАССИФИКАЦИИ МНОГОЗОНАЛЬНЫХ ИЗОБРАЖЕНИЙ ЛЕСНОЙ РАСТИТЕЛЬНОСТИ ОТ ПАРАМЕТРОВ ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЯ

А. И. Назмутдинова, В. Н. Милич

*Физико-технический институт УрО РАН,
426000, г. Ижевск, ул. Кирова, 132
E-mail: lssm@ftiudm.ru*

Рассмотрена задача классификации космических многозональных изображений объектов лесной растительности. Исследованы признаки, строящиеся на основе вейвлет-преобразования, и метод классификации, особенностью которого является учёт значимости каждого признака. Приведена зависимость результатов классификации от вейвлет-функции, уровня преобразования и параметра метода классификации — количества сегментов области значений признаков. Даны результаты классификации многозональных изображений шести классов лесной растительности на снимках, полученных с помощью съёмочной системы Rapid Eye.

Ключевые слова: многозональные изображения, метод классификации, вейвлет-преобразование, значимость признаков.

DOI: 10.15372/AUT20160303

Введение. Решение задачи интерпретации многозональных изображений поверхности Земли необходимо для мониторинга окружающей среды, обнаружения изменений объектов лесной растительности под влиянием внешних факторов, определения состояния сельскохозяйственных культур и др. Отдельные особенности фенологического состояния растительности отображаются в разных диапазонах электромагнитного спектра. Именно поэтому многозональные изображения имеют преимущество перед панхроматическими. Решению этой задачи посвящено большое количество работ (см. библиографию в [1]), однако она сохраняет свою актуальность. Традиционные методы классификации объектов по их многозональным изображениям основаны на различных дешифровочных признаках, которые делятся на спектральные и пространственные. При стандартном подходе в качестве признаков выступают значения пикселей в разных каналах многозонального изображения. Однако исследования показывают, что в некоторых случаях целесообразнее использовать пространственные признаки. Например, в [2] при решении задачи обнаружения изменений застройки выяснилось, что наиболее эффективны структурные пространственные признаки, определяющие максимальный угол свободного обзора. В данной работе для формирования признаков предлагается использовать вейвлет-преобразование, которое позволяет описывать сигнал сразу в двух областях — пространственной и частотной. Выполнение этого действия в разных спектральных зонах, характеризующих спектральные особенности объектов, даёт дополнительную информацию. Важным является выбор материнской вейвлет-функции и уровня преобразования [3].

Цель предлагаемой работы — создание метода классификации многозональных изображений объектов лесной растительности с использованием признаков, построенных на основе вейвлет-преобразования, и исследование зависимости результатов классификации от параметров вейвлет-преобразования. Для анализа полученных данных были взяты при-

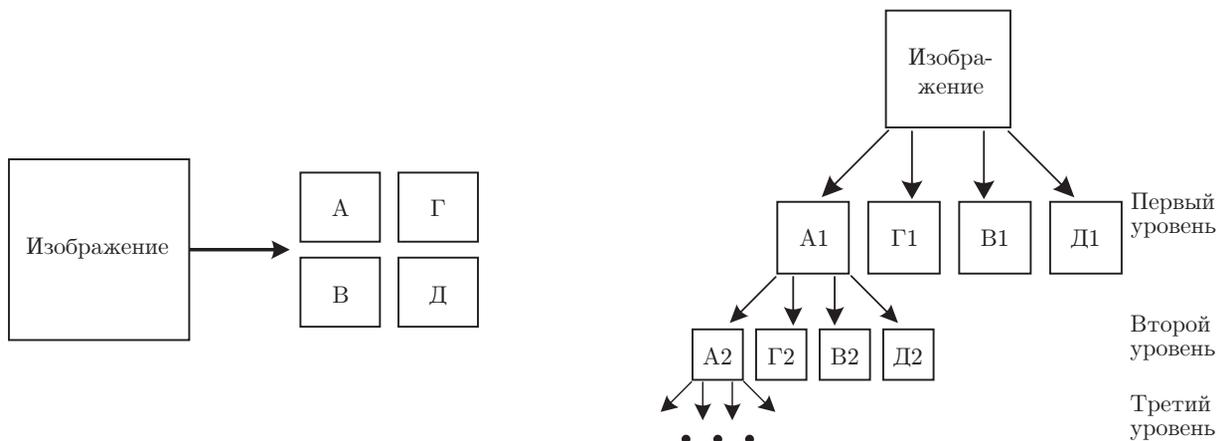


Рис. 1. Пространственное расположение изображений ДВП и схематическое представление уровней ДВП

нятые в настоящее время оценки точности классификации многозональных изображений, основанные на матрице ошибок, и коэффициент каппа (К) [4].

Формирование признаков. Известно, что вейвлет-преобразование обладает преимуществом, например, перед преобразованием Фурье [5], поскольку позволяет характеризовать исследуемый сигнал как в частотной области, так и в пространственной. В данной работе вейвлет-преобразование выполнялось с использованием стандартной схемы двумерного дискретного вейвлет-преобразования (ДВП) Малла [6], представленной в [7]. В результате ДВП, которое можно трактовать как последовательное применение низкочастотных и высокочастотных фильтров, вместо одного изображения на входе будем иметь четыре изображения ДВП на выходе. Каждое из них соответствует вертикальным (В), горизонтальным (Г), диагональным (Д) деталям, а также аппроксимации изображения (А). Для получения изображений ДВП следующего уровня необходимо взять в качестве исходного сигнала изображение аппроксимации и повторить с ним процедуру вейвлет-преобразования. В данной работе рассмотрены три уровня вейвлет-преобразования. На рис. 1 схематически представлены этапы формирования изображений ДВП. На рис. 2 приведены образец исследуемого снимка и результат его вейвлет-преобразования с помощью функции Хаара.

Таким образом, с помощью ДВП вместо одного изображения образуется несколько других изображений, которые имеют меньшее пространственное разрешение, чем исходное. В качестве признаков для классификации использованы среднее значение и стандартное отклонение, рассчитываемые по каждому из сформированных ДВП изображений. Эти

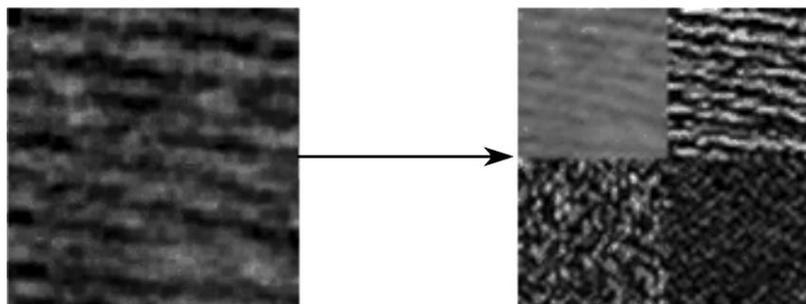


Рис. 2. Исходное изображение молодого хвойного леса (посадки) размером 64×64 пикселя и результат его вейвлет-преобразования с помощью функции Хаара

признаки были изучены и показали свою эффективность [7]. Для одного спектрального канала при проведении одноуровневого ДВП получим 8 признаков, на втором уровне — 16, а на третьем — 24. Для пяти спектральных зон и трёх уровней преобразования число признаков равно 120.

Вейвлет-функции. В предлагаемой работе рассматривается несколько вейвлет-функций, выбор которых обусловлен исследованиями [3]. Для дискретного случая алгоритм обработки изображения определяется коэффициентами масштабирующей функции вейвлета. Используемые вейвлеты обладают следующими свойствами [5].

Вейвлет Хаара хорошо локализован в пространственной области, однако вейвлет-функция имеет широкий частотный спектр. Вейвлеты Добеши ортогональны, асимметричны и обладают компактным носителем. В данной работе исследовался вейвлет Добеши второго порядка. Симлеты представляют собой квазисимметричные функции. Энергия таких вейвлетов сосредоточена в центральной части в отличие от вейвлетов Добеши. У койфлетов нулевой момент имеет не только вейвлет-функция, но и масштабирующая функция. Такие вейвлеты не являются симметричными. Вейвлет Шеннона — Котельникова определяется в комплексном пространстве. При этом масштабирующая функция представлена формулой $\sin c(\pi t) = \sin(\pi t)/\pi t$. В дискретном случае [5] коэффициенты данной функции выражаются по формуле

$$\text{sh}_n = \sqrt{2} \frac{1}{2\pi} \int_{-\pi/2}^{\pi/2} e^{i\omega n} d\omega = \begin{cases} 1/\sqrt{2}, & n = 0, \\ (-1)^{(n-1)/2} \sqrt{2}/\pi n, & n - \text{нечётное}, \\ 0 & \text{при других } n. \end{cases}$$

Здесь использован вейвлет Шеннона — Котельникова с семью коэффициентами: $-\sqrt{2}/3\pi$; 0; $\sqrt{2}/\pi$; $1/\sqrt{2}$; $\sqrt{2}/\pi$; 0; $-\sqrt{2}/3\pi$. Виды вейвлетов и масштабирующих функций известны и приведены в [3, 5].

Схема классификации. Предлагаемый в данной работе метод классификации принадлежит к категории контролируемых. На этапе обучения для эталонных образцов каждого исследуемого класса формируются векторы вейвлет-признаков так, как описано выше. По рассчитанным эталонам определяются диапазоны принимаемых значений признаков, т. е. за левую и правую границы диапазона берутся минимальное и максимальное значения признака во множестве эталонных образцов. Далее происходит сегментирование полученных диапазонов на равные отрезки, количество которых задаётся исследователем. Для каждого признака формируется вспомогательный массив L [8] по следующему правилу: $l_{ij} = 1$, если значение хотя бы одного образца i -го класса попадает в j -й сегмент, иначе $l_{ij} = 0$. С помощью этого массива находим для каждого из признаков показатель значимости, определяемый по частично модифицированной формуле из [8]:

$$F = 1 - \left(\sum_{i=1}^M \left(\sum_{j=1}^{nz} \left(l_{ij} \sum_{k=1, k \neq j}^M l_{kj} \right) / \sum_{j=1}^{nz} l_{ij} \right) / M(M-1) \right), \quad (1)$$

где M — количество классов; nz — количество сегментов, на которое разбиты диапазоны значений признаков. Величина показателя значимости, вычисленная по такой формуле, тем больше, чем меньше представителей разных классов попадает в один сегмент диапазона.

Кроме показателя значимости признаков (1) на этапе обучения рассчитываются значения достоверности, которые характеризуют вероятность принадлежности исследуемого образца классу i , если значение рассматриваемого признака образца попадает в сегмент j .

Массивы достоверностей строятся для каждого признака по формуле, основанной на алгоритме, изложенном в [8]:

$$\mu_{ij} = \left(\frac{m_{ij}}{N_i} l_{ij} \right) / \left(\sum_{i=1}^K \frac{m_{ij}}{N_i} l_{ij} \right), \quad (2)$$

где m_{ij} — количество образцов i -го класса, значения которых по рассматриваемому признаку попадают в j -й сегмент; N_i — общее количество обучающих образцов i -го класса.

На этапе принятия решения исследуемый образец представляется вектором вейвлет-признаков. По каждому признаку j определяется сегмент s_j , в который попадает значение признака этого образца. Для всех классов i , чьи обучающие образцы оказались в том же сегменте, что и признак тестового образца, рассчитывается значение приоритета:

$$\text{pri}_{ij} = F_j \mu_{is_j}. \quad (3)$$

Вычисленные значения приоритета по признаку (3) являются базовыми характеристиками принадлежности к классу. Путём суммирования приоритетов по признакам j получаем вектор значений pri , размерность которого равна числу исследуемых классов. Тестируемый образец относится к классу с наибольшим значением pri .

Оценка точности. Результаты классификации были оценены с помощью матрицы ошибок [4], представляющей собой таблицу, в которой столбцы — справочная (достоверная) информация для множества исследуемых образцов, а строки — результаты проведённой классификации. Соответственно элементы, расположенные на главной диагонали матрицы, определяют количество образцов, отнесённых в результате классификации к классу, которому они принадлежат согласно справочным данным. Широко используемым показателем, рассчитываемым по матрице ошибок, является общая точность (ОТ):

$$\text{ОТ} = \left(\sum_{i=1}^k x_{ii} / n \right) \cdot 100 \%, \quad (4)$$

где в числителе стоит сумма диагональных элементов матрицы ошибок, а n — общее количество тестовых образцов. Для оценки результатов классификации часто применяется коэффициент K [4]:

$$K = \left(n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+n+j} \right) / \left(n^2 - \sum_{i=1}^k n_{i+n+j} \right). \quad (5)$$

Здесь n_{+j} — сумма j -го столбца в матрице ошибок; n_{i+} — сумма i -й строки. Коэффициент K основывается на максимальном правдоподобии и отличается от других показателей тем, что стремится учесть так называемую случайную согласованность справочных данных и полученного решения. Он может принимать значения в диапазоне от -1 до 1 . При этом, если значение показателя близко к 1 , то метод классификации считается более эффективным, чем случайный выбор. Соответственно, если это значение близко к 0 или отрицательно, то полагается, что нет существенной разницы между применённым методом классификации и случайным выбором. Таким образом, коэффициент K позволяет сравнивать результаты классификации, различающиеся методами и условиями задачи (количество признаков, состав признаков, количество тестовых образцов).

Исходные данные. Для тестирования описанной схемы классификации на снимке, полученном с помощью съёмочной системы Rapid Eye, были выбраны шесть классов объектов лесной растительности, которые описаны в табл. 1. Данный снимок сделан в июле 2011 года и состоит из пяти спектральных зон. Обучение проведено по пяти эталонам для каждого класса. При этом все эталонные и тестовые образцы имеют размеры 16×16 или 32×32 пикселя.

Таблица 1

Классы объектов

№ п/п	Объём тестов	Описание класса
1	20	Смешанный лес (берёза, сосна)
2	20	Лиственный лес (берёза, осина)
3	21	Ель (сомкнувшиеся культуры)
4	21	Лиственный лес (липа, берёза, осина)
5	20	Молодой хвойный лес (посадки)
6	22	Вырубки с подростом

Результаты. В качестве базового варианта исследования выполнена классификация объектов лесной растительности (см. табл. 1) с использованием признаков, построенных на основании одноуровневого вейвлет-преобразования Хаара. Количество сегментов, на которое разбиваются диапазоны значений признаков, принималось равным шести. Полученная матрица ошибок демонстрирует высокую точность результатов (табл. 2). Показатель общей точности (4) и коэффициент К (5) достигают 90 % и 0,87 соответственно. Сравнение результатов данной работы с результатами, полученными спектральными и классическими текстурными методами, показывает следующее. Использование только спектральных характеристик [9] приводит к результатам классификации, например, лиственных лесов с общей точностью 85 %. Классические текстурные методы с признаками Харалика [10] позволяют достичь довольно высоких результатов (общая точность равна 92 %), однако в этой работе классы объектов различимы даже визуально. В [11] применён комплекс, включающий текстурные и спектральные признаки. В число объектов входят разновидности городской застройки, растительность, нефтяные пятна, грунты. Общая точность составляет 83–87 %.

Для исследования зависимости результатов классификации от вейвлет-функции был проведён ряд экспериментов с разными вейвлетами. При этом признаки строились на основе одноуровневого преобразования (40 признаков, 6 сегментов при разбиении диапазонов значений признаков). Полученные результаты (табл. 3) показывают эффективность предложенного метода. Наиболее оптимальными функциями для наших исследований являются вейвлеты Хаара, Шеннона — Котельникова и симлет. В целях исследования зависимости результатов классификации от уровня ДВП проанализирована значимость признаков, которые были построены на изображениях, полученных в результате трёх уровней ДВП (всего 120 признаков). В число 19 признаков, основанных на трёхуровневом вейвлет-

Таблица 2

Матрица ошибок классификации
с признаками одноуровневого вейвлет-преобразования Хаара

№ класса	1	2	3	4	5	6	n_{+i}
1	19	1	1	0	0	1	22
2	0	17	0	1	0	0	18
3	0	0	18	0	0	0	18
4	1	2	1	20	2	0	26
5	0	0	0	0	16	0	16
6	0	0	1	0	2	21	24
n_{j+}	20	20	21	21	20	22	124

Таблица 3
Результаты классификации для разных вейвлет-функций

Вейвлет-функция	Общая точность, %	Коэффициент К
Хаара	90	0,87
Добеши	87	0,85
Койфлет	84	0,81
Симлет	93	0,91
Шеннона — Котельникова	93	0,91

Таблица 4
Результаты классификации для вейвлета Хаара

Число сегментов	Первый уровень ДВП		Второй уровень ДВП		Третий уровень ДВП	
	ОТ, %	К	ОТ, %	К	ОТ, %	К
4	89	0,86	90	0,87	92	0,90
6	90	0,87	90	0,87	90	0,88
8	85	0,82	90	0,87	92	0,90
10	85	0,82	90	0,88	92	0,90
12	86	0,84	89	0,86	86	0,84

Таблица 5
Результаты классификации для симлета

Число сегментов	Первый уровень ДВП		Второй уровень ДВП		Третий уровень ДВП	
	ОТ, %	К	ОТ, %	К	ОТ, %	К
4	90	0,87	93	0,91	91	0,89
6	93	0,91	89	0,86	92	0,90
8	89	0,86	90	0,88	91	0,89
10	85	0,83	89	0,86	90	0,88
12	77	0,73	87	0,85	90	0,87

Таблица 6
Результаты классификации для вейвлета Шеннона — Котельникова

Число сегментов	Первый уровень ДВП		Второй уровень ДВП		Третий уровень ДВП	
	ОТ, %	К	ОТ, %	К	ОТ, %	К
4	85	0,83	88	0,85	88	0,85
6	93	0,91	89	0,86	90	0,87
8	94	0,92	94	0,93	95	0,94
10	94	0,93	95	0,94	95	0,94
12	95	0,94	98	0,97	97	0,96

Таблица 7

Наилучшие параметры вейвлет-преобразования и метода классификации

Вейвлет-функция	Уровень ДВП	Число сегментов	ОТ, %	К
Хаара	1	6	90	0,87
	2	4–10	90	0,87
	3	4–10	92	0,90
Симлет	1	6	93	0,91
	2	4	93	0,91
	3	6	92	0,90
Шеннона — Котельникова	1	12–16	95	0,94
	2	12	98	0,97
	3	12	97	0,96

преобразовании Шеннона — Котельникова с показателем значимости (1), превышающим 0,75, вошли признаки, сформированные на втором и третьем уровнях по всем изображениям ДВП (А, В, Г, Д), т. е. эти признаки содержат дополнительную полезную информацию и обладают высокой разделяющей силой.

Кроме того, проведён ряд экспериментов с признаками, сформированными на втором и третьем уровнях ДВП с использованием вейвлетов Хаара, Шеннона — Котельникова и симлета. Результаты для разных вейвлет-функций, уровней ДВП и разного количества сегментов сведены в табл. 4–6.

Анализ таблиц показал, что при работе с признаками, построенными на основе вейвлет-преобразования Хаара, с увеличением уровня ДВП происходит определённый рост показателей точности. Это характерно для всех рассматриваемых значений параметра количества сегментов, кроме числа сегментов 12, при котором наблюдается существенный спад оценок точности. Для симлета повышение уровня ДВП и количества сегментов не приводит к принципиальным изменениям результатов. Данные, полученные с использованием признаков, построенных на основе вейвлет-преобразований Шеннона — Котельникова, демонстрируют увеличение числа сегментов при росте показателей точности. Наиболее высокие значения общей точности и коэффициента К (ОТ = 98 %, К = 0,97) достигнуты при 12 сегментах и двухуровневом ДВП.

Для обобщения результатов в табл. 7 представлены наилучшие комбинации параметров, позволяющие получать наиболее высокие показатели точности классификации.

Заключение. Исследование зависимости результатов классификации от различных параметров ДВП и предложенного метода привело к следующим выводам.

1. Данные экспериментов демонстрируют эффективность признаков, построенных на основе вейвлет-преобразования с учётом их показателей значимости.

2. Лучшими вейвлет-функциями являются вейвлеты Хаара, Шеннона — Котельникова и симлет.

3. Признаки, полученные на втором и третьем уровнях вейвлет-преобразования, вносят дополнительную полезную информацию для разделения классов.

4. Для вейвлета Хаара наиболее полезно одновременное применение признаков трёх уровней ДВП, при этом количество сегментов в диапазоне от четырёх до десяти даёт сходные результаты.

5. При работе с симлетом целесообразно строить признаки на первом уровне ДВП, а классификацию проводить с количеством сегментов от четырёх до шести.

6. Наиболее эффективный набор параметров метода классификации: вейвлет Шеннона — Котельникова, уровень вейвлет-преобразования два, количество сегментов 12.

СПИСОК ЛИТЕРАТУРЫ

1. **Шовенгердт Р. А.** Дистанционное зондирование. Методы и модели обработки изображений. М.: Техносфера, 2010. 560 с.
2. **Борзов С. М., Потатуркин А. О., Потатуркин О. И.** Обнаружение изменений территории застройки на основе применения структурных признаков спутниковых изображений // Автометрия. 2015. **51**, № 4. С. 3–11.
3. **Fdez-Sarria A., Ruiz L. A., Recio J. A.** Study of methods based on wavelets for texture classification of high resolution images // Proc. of the 25th EARSeL Symposium "Global Developments in Environmental Earth Observation from Space". Porto, Portugal, 2005. P. 19–27.
4. **Congalton R. G., Green K.** Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Boca Raton: CRC Press, 2009. 183 p.
5. **Смоленцев Н. К.** Основы теории вейвлетов. Вейвлеты в MATLAB. М.: ДМК Пресс, 2005. 304 с.
6. **Гонсалес Р., Вудс Р.** Цифровая обработка изображений. М.: Техносфера, 2005. 1104 с.
7. **Назмутдинова А. И., Милич В. Н.** Алгоритмическое и программное обеспечение вейвлет-анализа многозональных космических снимков // Всеросс. науч.-практ. конф. «Инновации в науке, технике и технологиях». Ижевск: ИЦ «Удмуртский университет», 2014. С. 189–191.
8. **Вагин В. Н., Головина Е. Ю., Загорянская А. А., Фомина М. В.** Достоверный и правдоподобный вывод в интеллектуальных системах. М.: Физматлит, 2004. 704 с.
9. **Chen J., Chen D., Blostein D.** Wavelet-based classification of remotely sensed images: A comparative study of different feature sets in an urban environment // Journ. Environmental Informatics. 2007. **10**, N 1. P. 2–9.
10. **Bekkari A., Idbraim S., Elhassouny A. et al.** Classification of high resolution urban satellites images using SVM and Haralick features with a hybrid median filter // Intern. Journ. Comput. Appl. 2012. Special Issue: SEDEXS, N 1. P. 35–40.
11. **Akar Ö., Güngör O.** Classification of multispectral images using Random Forest algorithm // Journ. Geodesy and Geoinform. 2012. **1**, Is. 2, N 106. P. 105–112.

Поступила в редакцию 10 июля 2015 г.