

ДИСТАНЦИОННОЕ ЗОНДИРОВАНИЕ И МОНИТОРИНГ ЗЕМЕЛЬ

УДК 550.837.82:528

DOI: 10.30533/0536-101X-2018-62-1-85-95

Анализ информативности спектральных и текстурных признаков при классификации растительности по гиперспектральным аэроснимкам

© 2018 г. Л.Н. Чабан*, К.В. Березина

Московский государственный университет геодезии и картографии, Москва, Россия

*lusychaban@mail.ru

Analysis of the informativeness of spectral and texture features while classifying the vegetation on hyperspectral airborne imagery

L.N. Chaban*, K.V. Beriozina

Moscow State University of Geodesy and Cartography, Moscow, Russia

*lusychaban@mail.ru

Received September 12, 2017

Accepted January 22, 2018

Keywords: hyperspectral images, image processing, remote sensing, texture features, vegetation classification.

Summary. The article discusses the results of experiments on the joint use of spectral and texture features to classify vegetation cover on airborne hyperspectral images with a spatial resolution of 1 m per pixel. Images were obtained by the experimental sensor with 290 bands in the range 400–1000 nm. The most informative bands have been selected for each scene. Different types of forest vegetation were mainly represented in the analyzed scenes. The informative content of the eight texture features (co-occurrence measures) from the ENVI package was studied in different spectral ranges and for different window sizes. Statistical separability of training samples and quality of classification in the whole image were evaluated for the spectral and texture features. All the experiments showed that the most informative texture features might be obtained in the near-infrared range when the window had size of 7×7 pixels. Despite the good separability of samples for the texture features, the final results of classification showed that the classification of spectral features in most cases gives the best results. Texture features can improve the classification quality only using a small number of bands. But to boost the informativeness it should be dealt with an individual for each scene set of texture features. The article provides two examples to illustrate this statement.

Citation: Chaban L.N., Beriozina K.V. Analysis of the informativeness of spectral and texture features while classifying the vegetation on hyperspectral airborne imagery. *Izvestiya vuzov «Geodeziya i aerofotosyemka»*. *Izvestia vuzov «Geodesy and Aerophotosurveying»*. 2018, 62 (1): 85–95. [In Russian]. DOI: 10.30533/0536-101X-2018-62-1-85-95.

Поступила 12 сентября 2017 г.

Принята к печати 22 января 2018 г.

Ключевые слова: гиперспектральные снимки, дистанционное зондирование, классификация растительности, обработка изображений, текстурные признаки.

Рассматриваются результаты экспериментов по совместному использованию спектральных и текстурных признаков для классификации растительного покрова на авиационных гиперспектральных изображениях. Проанализирована информативность текстурных признаков, предлагаемых в пакете ENVI, на различных участках спектра в диапазоне 400–1000 нм. Приведены примеры, в которых совместное использование спектральных и текстурных признаков позволяет повысить точность классификации.

Для цитирования: Чабан Л.Н., Березина К.В. Анализ информативности спектральных и текстурных признаков при классификации растительности по гиперспектральным аэроснимкам // Изв. вузов «Геодезия и аэрофотосъемка». 2018. Т. 62. № 1. С. 85–95. DOI: 10.30533/0536-101X-2018-62-1-85-95.

Гиперспектральные изображения в последние двадцать лет стали одним из важных источников видеоданных, используемых для классификации и оценки состояния различных типов растительности. Непрерывная последовательность узких спектральных каналов таких изображений детально описывает изменение спектральной яркости растительности в зависимости от длины волны регистрируемого излучения. Это позволяет использовать локальные особенности спектральных кривых как для изучения биофизических и биохимических процессов, протекающих в растительных клетках, так и для более точной и детальной классификации типологического состава растительного покрова. Наиболее интересны для значительной части прикладных задач видимый и ближний инфракрасный диапазоны (400–1300 нм).

На территории РФ одни из наиболее практически значимых задач – инвентаризация и оценка состояния лесного фонда. Классификации лесной растительности по гиперспектральным изображениям уделяется достаточно много внимания и в зарубежных исследованиях [1–3]. Однако, несмотря на более высокую информативность гиперспектральных снимков по сравнению с мультиспектральными, возможности типологической классификации лесов только по спектральным признакам ограничены. Кроме того, при тематической классификации гиперспектральных снимков возникает проблема выбора метода классификации, связанная с большой размерностью видеоданных. Методы статистической параметрической классификации с обучением (расстояние Махаланобиса, байесовский классификатор) в этом случае требуют неприемлемо большого объема обучающих выборок, что приводит к необходимости существенного сокращения размерности исходных данных. Большое число каналов при небольших размерах обучающих выборок позволяет использовать непараметрические методы, среди которых линейный дискриминантный анализ и метод опорных векторов [1]. Однако в указанных методах требуется высокая достоверность обучающих данных, которую

при классификации лесной растительности из-за высокой вариабельности спектральных характеристик лесного полога обеспечить чрезвычайно сложно.

Для более детальной типологической классификации используют авиационные и космические снимки с пространственным разрешением 1–5 м/пиксель, которые позволяют получить информацию не только о спектральных яркостных характеристиках, но и о структуре лесного полога. Мульти- и гиперспектральная съемка с таким пространственным разрешением позволяет использовать при типологической классификации и спектральные, и текстурные признаки. В последние годы данному направлению исследований уделяется значительное внимание. Так, в работе [1] при классификации лесов по гиперспектральным изображениям с авиационной аппаратуры CASI применялся ряд гистограммных признаков второго порядка [4], в работе [5] для тематической обработки гиперспектральных снимков с аппаратуры НуМар авторы использовали собственные текстурные (геостатистические) признаки. Однако технология обработки в обоих случаях содержала значительный объем оригинальных процедур и вряд ли пригодна для массового использования. Для разработки методологий, доступных широкому кругу пользователей, целесообразно базироваться на возможности текстурного анализа средствами популярных пакетов обработки данных дистанционного зондирования, например, ERDAS Imagine и ENVI.

Текстурные признаки

Последние версии пакета ENVI позволяют рассчитать в окне заданного размера $x \times y$ восемь текстурных признаков [4]:

- 1) среднее значение яркости ($f_1 = u$);
- 2) дисперсия

$$\hat{f}_2 = \sum_i \sum_j (i - u)^2 p(i, j),$$

где $i, j = 1, \dots, N_g$; N_g — общее число уровней яркости; i, j — индексы матрицы смежности уровней яркости в анализируемом окне;

3) «однородность» (обратная разность [4])

$$\hat{f}_3 = \sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j);$$

4) контраст [7]

$$\hat{f}_4 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{\substack{j=1 \\ |i-j|=n}}^{N_g} p(i, j) \right\};$$

5) «неоднородность»

$$\hat{f}_5 = \sum_{n=0}^{N_g-1} n \left\{ \sum_{i=1}^{N_g} \sum_{\substack{j=1 \\ |i-j|=n}}^{N_g} p(i, j)^2 \right\};$$

6) энтропия

$$\hat{f}_6 = - \sum_i \sum_j p(i, j) \log(p(i, j));$$

7) энергия

$$\hat{f}_7 = \sum_i \sum_j [p(i, j)]^2;$$

8) корреляция

$$\hat{f}_8 = \sum_i \sum_j \frac{(i, j) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}.$$

Результат расчета каждого признака при-
сваивается на выходе текущему центральному
элементу окна.

Цели и задачи исследования

В настоящей работе на доступных материалах аэросъемки с отечественного гиперспектрометра проанализированы возможности совместного использования спектральных и текстурных признаков при типологической классификации растительного покрова средствами указанных ранее пакетов. Анализ информативности перечисленных текстурных признаков для классификации изображений лесной растительности предусматривал ряд задач.

1. Выбор фрагментов гиперспектральных снимков с репрезентативным набором тематических классов, содержащих наиболее распространенные в зоне бореальных лесов типы растительного покрова.

2. Определение спектрального диапазона (диапазонов), в котором использование текстурных признаков обеспечивает наилучшую

разделимость растительных классов.

3. Оценка информативности каждого из перечисленных текстурных признаков применительно к заданному перечню классов.

4. Сравнительный анализ информативности спектральных и текстурных признаков.

5. Изучение возможностей совместного использования спектральных и текстурных признаков в процессе тематической классификации.

Исходные данные

Тестовым материалом служили гиперспектральные изображения, полученные в 2012 г. на территории Тверской области экспериментальным авиационным гиперспектрометром, разработанным ЗАО НПО «Лептон» [8]. Пространственное разрешение изображения — около 1 м/пиксель, радиометрическое — 12 бит/пиксель. Гиперспектрометр имеет 290 каналов в диапазоне 400–1000 нм, ширина каналов от 1 нм в голубом диапазоне до 11 нм в ближнем инфракрасном. Из 290 исходных каналов рабочего диапазона аппаратуры обработка выполнялась на 190 каналах из диапазона 450–1000 нм, поскольку каналы шириной 1 нм имеют низкое отношение сигнал/шум и не содержат важной информации для выполнения тематической обработки.

Методика исследования

Для выполнения экспериментов выбрано несколько сцен с различными типами растительного покрова. На всех сценах преобладала лесная растительность, однако присутствовали также дороги, постройки и участки с травянистой и травянисто-кустарниковой растительностью. Во всех случаях использовалась классификация с обучением; эталоны классов выбирались на основе ретроспективных данных лесной таксации и наземных обследований, проведенных при выполнении съемочных работ. Размеры эталонных участков — от 200 до 500 пикселей.

На первом этапе исследований выполнена спектрально-угловая классификация тестовых изображений по всем 190 каналам. Мерой сходства в данном методе служит угол α между

средней спектральной сигнатурой эталона и спектральной сигнатурой тестируемого пикселя, который вычисляется по формуле

$$\alpha = \arccos \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i^2}}$$

Данный метод дает наиболее высокую точность классификации в тех случаях, когда на изображении преобладают классы примерно одного уровня пространственной однородности, независимо от особенностей текстуры. При этом на изображениях высокого разрешения он позволяет частично избавиться от ошибок, связанных с неравномерной освещенностью крон деревьев. Однако на сценах, содержащих классы с различным уровнем пространственной однородности, данный метод приводит к значительному перераспределению пикселей в пользу более однородных классов, что и подтвердили выполненные численные эксперименты.

В связи с этим при дальнейших исследованиях использовалась статистическая параметрическая классификация с предварительным отбором каналов на основе анализа главных компонент. Для каждого изображения использовался набор каналов, дающих максимальный вклад в наиболее информативные главные компоненты. Как показали ранее проведенные численные эксперименты [8], из-за переменной ширины каналов этот метод сокращения размерности — наиболее подходящий для данного типа гиперспектральных изображений. Из параметрических методов классификации выбрано расстояние Махаланобиса, которое в большинстве случаев давало наилучшую точность при классификации на контрольных выборках.

Предварительно информативность признаков оценивалась путем выяснения статистической разделимости эталонов выбранных классов. Мерой статистической разделимости служила трансформированная дивергенция

$$TD_{ij} = 2000 \left(1 - \exp \left(\frac{-D_{ij}}{8} \right) \right),$$

где D_{ij} — среднее количество различающей информации в предположении, что признаки в классах распределены по нормальному закону; для классов i и j рассчитывается по формуле [9]

$$D_{ij} = \frac{1}{2} \text{tr}[(C_i - C_j)(C_j^{-1} - C_i^{-1})] + \frac{1}{2} [(C_i^{-1} + C_j^{-1})(m_i - m_j)(m_i - m_j)^T].$$

При полной разделимости эталонов классов трансформированная дивергенция принимает значение 2000. Выбор данной меры обусловлен ее идентичными значениями в пакетах ERDAS Imagine и ENVI. Однако полная статистическая разделимость далеко не всегда означает, что классификация, даже наилучшим для конкретного набора эталонов методом, даст самый хороший результат для сцены в целом. Поэтому окончательная оценка выполнялась по результатам классификации всего изображения. Заметим, что авторы работы [1] в итоге пришли к выводу, что преимущества от использования текстурных признаков практически полностью нивелируются в результате постклассификационной обработки средствами растрового ГИС-анализа. Учитывая этот факт, вполне подтвердившийся нашими экспериментами, из всей серии выполненных экспериментов здесь мы рассмотрим два примера, в которых текстурные признаки позволяли повысить точность классификации сцены в целом.

Первое изображение содержало участок леса с известным составом растительности, а также примыкающие к лесу постройки и фрагмент шоссеной дороги (рис. 1). На рис. 1, б показаны участки восьми представленных на изображении классов размером около 250 пикселей.

Приведем набор из десяти каналов, полученный в результате отбора по методике, изложенной в исследовании [8]:

Номер канала	130	188	196	245	254	261	264	276	279	284
λ , нм	474	540	553	679	717	753	771	860	888	941

Спектральные профили эталонов классов в отобранных десяти каналах в полной мере отражают особенности их спектральных образов (рис. 2). По относительному положению профилей наихудшую точность классификации следует ожидать для пары «сосна–береза» из-




Рис. 1. RGB-композиции тестового изображения:

a — в естественных цветах (RED=679 нм, GREEN=540 нм, BLUE=474 нм); *б* — наиболее информативная (RED=753 нм, GREEN=553 нм, BLUE=474 нм). Цифрами обозначены эталоны классов: 1 — сосна; 2 — береза; 3 — ольха; 4 — ива; 5 — трава; 6 — почва+трава; 7 — песок; 8 — искусственные покрытия (дороги, крыши)

Fig. 1. RGB composition of the test image:

a — natural colors (RED = 679 nm, GREEN = 540 nm, BLUE = 474 nm); *б* — the most informative colors (RED = 753 nm, GREEN = 553 nm, BLUE = 474 nm); class samples: 1 — pine, 2 — birch, 3 — alder, 4 — willow, 5 — grass, 6 — soil+grass, 7 — sand, 8 — artificial surface (roof, road)

за высокой дисперсии яркости класса «береза» во всех диапазонах.

Выбор спектрального диапазона для расчета текстурных признаков

С целью сравнительного анализа для всех десяти отобранных каналов рассчитаны восемь перечисленных выше текстурных признаков в окне размером 5×5 , 7×7 , 9×9 и 11×11 элементов. Наилучший результат по пространственной однородности текстурных признаков получен при окне 7×7 элементов (рис. 3). Отметим, что данный результат совпадает с результатами, полученными в работах [1, 5] и другими авторами, упомянутыми в этих работах.

В результате были сформированы десять изображений, каждое из восьми слоев, где каждый слой соответствовал определенному текстурному признаку f_k с введенной выше нумерацией ($k = 1, \dots, 8$). Для адекватного сравнения и совместного использования спектральных и текстурных признаков все текстурные изображения были преобразованы к целочисленной шкале, сопоставимой с радиометрическим разрешением исходного гиперспектрального изображения.

Итоговые результаты оценки попарной статистической разделимости классов в десяти спектральных каналах для изображений из восьми текстурных слоев, приводятся в табл. 1.

Приведенные в табл. 1 результаты показы-

вают, что наилучшая статистическая разделимость по текстурным признакам наблюдается в ближнем инфракрасном диапазоне, в котором величина отраженного растительностью излучения максимальна. По всей совокупности оценок наилучший результат соответствует каналу 8 (860 нм). Сопоставимые с каналом 8 результаты дает только зеленый канал 2 (540 нм), близкий к максимуму отражательной способности растительности в видимом диапазоне. Правда, несмотря на довольно низкую оценку статистической разделимости пары «сосна–береза» по десяти спектральным признакам (значение 1715 в нижней строке табл. 1), в целом статистическая разделимость классов в десяти спектральных каналах остается достаточно высокой.

Анализ информативности текстурных признаков

При анализе информативности текстурных признаков рассматривались парная статистиче-






Рис. 2. Спектральные профили выбранных классов (средние по эталонным участкам)

Fig. 2. Spectral profiles of selected classes (medians of training samples)

ская разделимость классов по каждому текстурному признаку во всех десяти каналах, а также относительное взаимное положение средних



а



б

Рис. 3. RGB-композиции, составленные из текстурных признаков по каналу 860 нм:

а — RED= f_4 , GREEN= f_3 , BLUE= f_2 ; б — RED= f_6 , GREEN= f_5 , BLUE= f_1

Fig. 3. RGB composition of texture features in channel 860 nm:

а — RED = f_4 , GREEN = f_3 , BLUE = f_2 ; б — RED = f_6 , GREEN = f_5 , BLUE = f_1

Таблица 1

Статистическая разделимость пар классов по восьми текстурным признакам

Канал	Длина волны, нм	Минимум D_{ij}	Классы с наихудшей разделимостью	Число пар классов с $D_{ij} < 1999$	Среднее при $D_{ij} < 1999$
1	474	1298	Сосна/Береза	5	1838
2	540	1922	Береза/Ольха	3	1967
3	553	1761	Ива/Почва+трава	3	1905
4	679	1831	Сосна/Береза	2	1901
5	717	1659	—	3	1872
6	753	1770	—	2	1883
7	771	1798	—	2	1872
8	860	1935	—	2	1944
9	888	1901	Ива/Почва+трава	2	1918
10	941	1800	—	4	1943
Десять спектральных каналов		1715	Сосна/Береза	8	1954

значений текстурного признака по классам (текстурные профили). По текстурным профилям можно получить дополнительную информацию об информативности конкретной пары «канал–текстура» для лучшего разделения отдельных классов. Однако в данном случае анализ таких профилей только подтвердил выбор канала 860 нм как наиболее информативного.

Разделимость пар классов по каждому из текстурных признаков в десяти каналах показана в табл. 2. Знак «+» соответствует полной разделимости по данному признаку ($D_{ij}=2000$). Для остальных пар классов (не показанных в таблице) $D_{ij}=2000$ по всем текстурным признакам.

Приведенные в табл. 2 результаты показывают, что усреднение спектральной яркости по окну 7×7 (признак 1) повышает разделимость классов по спектральным признакам. Из остальных признаков наиболее интересна функция контрастности Харалика (признак 4), а в некоторых случаях — функция «неоднородности» (признак 5) и энтропия (признак 6). Остальные текстурные признаки для данной сцены менее информативны.

Аналогичный анализ для других сцен показал, что в некоторых случаях достаточно информативной оказываются также обратная разность (признак 3) и значительно реже —

Таблица 2

Разделимость пар классов по отдельным текстурным признакам

Пара классов	Номер признака							
	1	2	3	4	5	6	7	8
Сосна/Береза	+	–	–	+	–	–	–	–
Сосна/Ольха, ива	+	+	–	+	+	–	–	–
Сосна/Трава, почва+трава	+	+	–	+	+	+	+	–
Береза/Ольха	+	+	–	+	–	–	–	–
Береза/Ива	+	+	–	+	–	+	+	+
Береза/Трава	+	–	–	–	–	+	+	–
Ольха/Трава	+	+	+	+	+	+	+	–
Ива/Трава	+	–	+	–	–	+	–	–
Ива/Почва+трава	+	+	–	+	+	–	–	–
Ива/Асфальт	+	+	+	+	+	+	+	–
Трава/Почва+трава	+	+	–	+	+	+	–	–
Трава/Асфальт	+	+	+	+	+	+	+	–
Почва+трава/Песок, асфальт	+	+	+	+	+	+	+	–
Песок/Асфальт	+	+	–	+	–	–	–	–

корреляция (признак 8). Дисперсия (признак 2) во всех случаях не имела никаких преимуществ перед указанными выше признаками, а наименее информативным признаком в целом оказалась энергия (признак 7).

Результаты тематической классификации

Выполнение оценок, приведенных здесь, сопровождалось классификацией изображений на заданное число классов. Сразу заметим, что, несмотря на более высокую статистическую разделимость эталонов, ни один из текстурных признаков не позволил получить результат, по качеству сопоставимый с результатом классификации по десяти спектральным каналам. Лучшие результаты показало комбинирование нескольких спектральных каналов с наиболее информативными текстурными признаками (рис. 4). Для рассматриваемой сцены использованы восемь каналов из десяти (без каналов 7 и 9) и текстурные признаки f_1, f_4, f_6 .

Использование комбинированных признаков (см. рис. 4, б) позволило значительно уменьшить ошибку по классу «сосна»: при классификации по десяти спектральным признакам к нему отнесены затененные участки с травянистой растительностью, в то же время по краям сцены в нем появились классы «береза» и «ива». И хотя по классам «трава», «трава+почва» и «искусственные покрытия» во втором случае также не удалось добиться «идеального» разделения, здесь наблюдается более высокая точность, чем в первом случае.

Второй заслуживающий внимания результат получен по фрагменту изображения лесной растительности с преобладанием класса сосны различного возраста и состояния (рис. 5). Данная сцена — одна из наиболее сложных, так как на ней присутствуют участки с несомкнутым пологом, а также взрослая сосна с подростом. На рис. 5, б хорошо заметны усыхающие дере-




Рис. 4. Результаты классификации изображения на восемь классов:

а — по 10 спектральным каналам; *б* — по 8 спектральным каналам и текстурным признакам f_1, f_4, f_6

Fig. 4. Results of the image classification into 8 classes:

a — 10 spectral features; *b* — 8 spectral features and texture features f_1, f_4, f_6

вья, имеющие характерный голубой оттенок. Для лучшей интерпретации и наглядности результата в данном случае тени выделены в отдельный класс.

Для классификации данной сцены также были отобраны десять каналов:

Номер канала	108	176	184	212	244	251	260	264	274	280
λ , нм	456	523	534	584	675	703	747	771	843	898

В данном примере статистическая разделимость эталонов была немного ниже, чем в предыдущем случае, как по десяти спектральным, так и по всем текстурным признакам. Наихудшая разделимость наблюдалась для классов нормальной и усыхающей сосны, а также для классов «береза» и «сосна с подростом». Отметим, что сокращение каналов с десяти до трех, соответствующих обычному набору каналов мультиспектрального изображения (зеленый, красный, ближний ИК), в

данном случае незначительно ухудшало статистическую разделимость. Поэтому при комбинировании спектральных признаков с текстурными использовались только три канала (534, 675 и 747 нм), а из восьми текстур — четыре: f_1 , f_3 , f_4 , f_8 , и именно они оказались для данной сцены наиболее информативными.

Сравнение результатов классификации (рис. 6) показывает, что при классификации только по спектральным признакам оказывается заметно завышенной доля классов «сосна усыхающая», «береза» и «трава». Результат, полученный по трем спектральным и четырем текстурным признакам оказывается существенно более точным, несмотря на худшее выделение тонких деталей.

Обсуждение результатов

По результатам тематической классификации гиперспектральных изображений с ис-




Рис. 5. RGB-композиции изображения участка соснового леса:

a — в естественных цветах (RED=675 нм, GREEN=534 нм, BLUE=456 нм); *б* — наиболее информативная (RED=747 нм, GREEN=534 нм, BLUE=456 нм). Цифрами обозначены эталоны классов: 1 — сосна норма; 2 — сосна усыхающая; 3 — сосна молодая; 4 — сосна с подростом; 5 — береза; 6 — трава; 7 — почва; 8 — тени

Fig. 5. RGB compositions for the image fragment of pine forest:

a — natural colors (RED = 675 nm, GREEN = 534 nm, BLUE = 456 nm); *б* — the most informative colors (RED = 747 nm, GREEN = 534 nm, BLUE = 456 nm); classes samples: 1 — pine normal; 2 — pine drying; 3 — pine young; 4 — pine with undergrowth; 5 — birch; 6 — grass; 7 — soil; 8 — shadows

пользованием доступных широкому кругу пользователей текстурных признаков можно сделать ряд выводов.

1. Спектральные признаки имеют безусловное преимущество перед текстурными, несмотря на то, что оценки статистической разделимости классов и точности классификации по текстурным признакам на эталонах классов во многих случаях дают более оптимистичные результаты. Значительно эффективнее использование текстурных признаков при небольшом числе спектральных каналов, т.е. при мультиспектральной съемке.

2. Комбинирование спектральных и текстурных признаков в отдельных случаях может повысить точность классификации сцены в целом, однако в каждом отдельном случае требуется отбор наиболее информативных текстурных признаков с предварительным приведением их к шкале, сопоставимой с динамическим диапазоном спектральных яркостей.

3. Наиболее информативный спектральный диапазон для расчета текстурных при-

знаков — ближний ИК-диапазон. Однако не исключено, что использование отдельных текстурных признаков в других спектральных диапазонах для некоторых сцен будет более эффективно. Этот вопрос подлежит дальнейшим исследованиям.

4. Наилучший размер окна при пространственном разрешении около 1 м/пиксель — окно 7×7 пикселей. Несмотря на то, что при размерах окна 9×9 пикселей разделимость эталонов классов по текстурным признакам часто оказывается выше, такой размер окна приводит к ухудшению пространственной точности классификации сцены. Тем не менее, в тех случаях, когда границы между тематическими категориями на снимке недостаточно контрастны, использование окна размером 9×9 пикселей может оказаться более эффективным.

5. Из рассмотренных восьми текстурных признаков наиболее информативны во всех случаях оказались среднее значение f_1 и функция контрастности Харалика f_4 . Дисперсия f_2 и энер-




Рис. 6. Результаты классификации участка соснового леса на восемь классов:

а — по 10 спектральным каналам; *б* — по трем спектральным каналам и текстурным признакам f_1, f_3, f_4, f_8

Fig.6. Results of the pine forest classification into eight classes:

a — 10 spectral features; *b* — 3 spectral features and texture features f_1, f_3, f_4, f_8

гия f_7 на всех проанализированных нами примерах оказывались наименее информативными характеристиками по сравнению с остальными.

Отметим, что итоговое качество классификации с обучением зависит не только от выбора признаков, но и от удачного подбора эталонных участков, а также выбора подходящего метода классификации. Несмотря на то, что для удобства сопоставления результатов нами был выбран метод классификации по расстоянию Махаланобиса, в некоторых случаях определенная комбинация признаков дает лучший результат в сочетании с другим методом классификации. Комбинирование двух результатов классификации с использованием разных наборов спектральных и текстурных признаков позволяет частично компенсировать ошибки первого и второго рода по отдельным тема-

тическим классам. Разработка таких методик, наряду с упомянутым здесь использованием текстурных признаков из различных спектральных диапазонов, представляет интерес для дальнейших исследований.

Благодарности. Авторы выражают благодарность заведующему секцией кафедры ИУ-5 в Мытищинском филиале МГТУ им. Баумана И.С. Чумаченко за внимательное знакомство со статьей и ценные замечания.

Acknowledgments. The authors express their gratitude to the head of the section of the Department IU-5 in the Mytishchi branch of the Bauman MSTU I.S. Chumachenko for a careful reading of the article and the positive feedback on this work.

ЛИТЕРАТУРА

1. *Yuanyong Dian, Zengyuan Li, Yong Pang.* Spectral and Texture Features Combined for Forest Tree species Classification with Airborne Hyperspectral Imagery // *Indian Soc Remote Sens.* 2015. March. P. 101–107.
2. *Buddenbaum H., Schlerf M. & Hill J.* Classification of coniferous tree species and age classes using hyperspectral data and geostatistical methods // *International Journ. of Remote Sensing.* 2005. № 26 (24). P. 5453–5465. doi: 10.1080/01431160500285076.
3. *Du Y., Chang C.I., Ren H., Chang C.C., Jensen J.O., D'Amico F.M.* New hyperspectral discrimination measure for spectral characterization // *Optical Engineering.* 2004. № 4. P. 1777–1785.
4. *Прэнтт У.* Цифровая обработка изображений: Т. 2. М.: Мир, 1982. 492 с.
5. *Chica-Olmo M. and Abarca-Hernandez F.* Computing geostatistical image texture for remotely sensed data classification // *Computers and Geosciences.* 2000. V. 26. P. 373–383.
6. Интернет-ресурс: <http://www.harrisgeospatial.com/docs/backgroundtexturemetrics.html>.
7. *Haralick R., Shanmugan K., and Dinstein I.* Textural Features for Image Classification // *IEEE Transactions on Systems, Man, and Cybernetics.* 1973. № 6 (3). P. 610–621.
8. *Чабан Л.Н., Вечерук Г.В., Гаврилова Т.С.* Исследование возможностей классификации растительного покрова по гиперспектральным изображениям в пакетах тематической обработки данных дистанционного зондирования // *Тр. МФТИ.* 2009. Т. 1. № 3. С. 171–180.
9. *Дейвис Ш.М., Ландгребе Д.А., Филлипс Т.Л., Свейн Ф.Х., Хоффер Р.М., Ланденлауб Д.С., Ле Р.Ф. Сиева.* Дистанционное зондирование: количественный подход / Ред. Ф. Свейн, Ш. Дэйвис. М.: Недра, 1983. 415 с.

REFERENCES

1. *Yuanyong Dian, Zengyuan Li, Yong Pang.* Spectral and Texture Features Combined for Forest Tree species Classification with Airborne Hyperspectral Imagery. *Indian Soc Remote Sens.* 2015, March: 101–107.
2. *Buddenbaum H., Schlerf M. & Hill J.* Classification of coniferous tree species and age classes using hyperspectral data and geostatistical methods. *Intern. Journ. of Remote Sensing.* 2005. № 26 (24): 5453–5465. doi: 10.1080/01431160500285076.
3. *Du Y., Chang C.I., Ren H., Chang C.C., Jensen J.O., D'Amico F.M.* New hyperspectral discrimination measure for spectral characterization. *Optical Engineering.* 2004, 4: 1777–1785.
4. *Pratt U.* *Cifrovaya obrabotka izobrazhenij.* T. 2. Digital imaging: T. 2. Moscow: Mir, 1982: 492 p. [In Russian].
5. *Chica-Olmo M. and Abarca-Hernandez F.* Computing geostatistical image texture for remotely sensed data classification. *Computers and Geosciences,* 2000, 26: 373–383.
6. URL: <http://www.harrisgeospatial.com/docs/backgroundtexturemetrics.html>.
7. *Haralick R., Shanmugan K., and Dinstein I.* Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics.* 1973, 6 (3): 610–621.
8. *Chaban L.N., Vecheruk G.V., GavriloVA T.S.* *Issledovanie vozmozhnostej klassifikacii rastitel'nogo pokrova po giperspektral'nym izobrazheniyam v paketah tematicheskoy obrabotki dannyh distancionnogo zondirovaniya* Research capabilities in land cover classification on hyperspectral images in packages of thematic processing of remote sensing data. *Proceedings of MIPT.* 2009. 1 (3): 171–180 [In Russian].
9. *Davis Sh.M., Landgrebe D.A., Phillips T.L., Svein F.X., Hoffer R.M., Landenlaub D.S., Le R.F. Sieva.* *Distancionnoe zondirovanie: kolichestvennyj podhod.* Remote sensing: a quantitative approach. Eds. F. Swain, Sh. Davies. Moscow: Nedra, 1983. 415 p. [In Russian].