

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 528.72 : 004.93

ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ КЛАССИФИКАЦИИ
ГИПЕРСПЕКТРАЛЬНЫХ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ
ПРИРОДНЫХ И АНТРОПОГЕННЫХ ТЕРРИТОРИЙ*С. М. Борзов¹, А. О. Потатуркин¹, О. И. Потатуркин^{1,2},
А. М. Федотов^{2,3}¹Институт автоматизации и электрометрии СО РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 1²Новосибирский государственный университет,
630090, г. Новосибирск, ул. Пирогова, 2³Институт вычислительных технологий СО РАН,
630090, г. Новосибирск, просп. Академика Лаврентьева, 6

E-mail: borzov@iae.nsk.su

potaturkin@iae.nsk.su

Выполнены исследования эффективности ряда классических методов контролируемой классификации гиперспектральных данных на примере различения типов подстилающей поверхности в природных и антропогенных зонах. Рассмотрены методы минимального расстояния, опорных векторов, Махаланобиса, максимального правдоподобия. Значительное внимание уделено изучению зависимости точности классификации данных от количества и способа выбора спектральных признаков при применении перечисленных методов. Приведены экспериментальные результаты, полученные при обработке реальных гиперспектральных изображений ландшафтов различного типа.

Ключевые слова: дистанционное зондирование Земли, гиперспектральные изображения, классификация типов поверхностей, спектр отражения.

DOI: 10.15372/AUT20160101

Введение. Современное развитие средств дистанционного зондирования Земли (ДЗЗ) характеризуется активным внедрением технологий гиперспектральной (ГС) съёмки в видимом и инфракрасном диапазонах. Создана оптико-электронная аппаратура, позволяющая получать ГС-изображения земной поверхности высокого качества. Отличительной особенностью регистрируемых при такой съёмке данных является узкая ширина и большое количество спектральных каналов. На основе этого разработаны многочисленные подходы, реализующие анализ тонкой структуры спектров пикселей изображений и их классификацию путём сравнения со спектрами эталонных участков поверхности [1]. Однако для практического использования ГС-данных (в связи с гигантским объёмом поступающей информации) необходимо кратное увеличение мощности вычислительных средств, распараллеливание процессов обработки и значительное расширение каналов передачи данных, что требует больших затрат и сдерживает развитие технологий ГС-мониторинга поверхности Земли и околоземного пространства.

Для решения указанной проблемы могут быть применены два альтернативных подхода. Первый основан на сокращении объёма данных при решении конкретных прикладных задач путём выбора наиболее информативных спектральных каналов и подсистем призна-

*Работа выполнена при поддержке Российского фонда фундаментальных исследований (грант № 13-07-12202) и Президиума РАН (проект № 15.3).

ков [2, 3]. Во втором подходе объём данных уменьшается за счёт предварительной сегментации изображений и перехода к их позонной обработке по спектральным и пространственным признакам с учётом априорных сведений о положении и природе наблюдаемых объектов [4]. Эффективность указанных подходов в первую очередь зависит от выбранных методов кластеризации данных в спектральной и пространственной областях.

Достоверную оценку эффективности методов классификации ГС-изображений можно получить лишь на основе сопоставления результатов обработки реальных данных ДЗЗ и карт наземных (подспутниковых) наблюдений. К сожалению, количества имеющихся в общем доступе ГС-изображений для проведения подобных исследований зачастую недостаточно, а соответствующие им данные наземных наблюдений для верификации результатов классификации практически полностью отсутствуют, и это также является существенным сдерживающим фактором совершенствования перечисленных технологий.

В работах [5, 6] на примере анализа реальных ГС-изображений показано, что применение одновременно всех каналов далеко не всегда целесообразно. Так, эффективность классификации типов растительности практически не снижается при сокращении количества признаков в 20 раз (при правильном выборе). При этом очевидно, что методика формирования системы информативных признаков для каждой задачи мониторинга поверхности Земли представляет собой отдельную серьёзную проблему.

Целью данной работы является экспериментальное исследование эффективности классических методов контролируемой классификации гиперспектральных изображений природных и антропогенных территорий в зависимости от количества учитываемых спектральных признаков при различных способах их выбора.

Классификация типов растительности по ГС-изображениям природных зон. Исследование эффективности методов классификации данных ДЗЗ для природных зон проводилось на примере обработки гиперспектрального изображения (рис. 1, *a, b*), полученного в рамках программы AVIRIS (Airborne Visible Infrared Imaging Spectrometer) на



Рис. 1. Исходные данные: *a* — RGB-композит изображения природной зоны; *b* — область, ограниченная рамкой; *c* — фрагмент, использованный при обучении; *d* — картосхема классов для фрагмента

опытном полигоне Индиан Пайс (штат Индиана, США). Размер изображения 614×2677 пикселей, разрешение 20 м/пиксель, число каналов 220 в диапазоне 0,4–2,5 мкм, при этом 20 каналов, содержащих высокий уровень шума, при проведении исследований удалены из рассмотрения. На изображении представлены: магистраль, железная дорога, сельскохозяйственные культуры, лес, жилые постройки.

По результатам наземных наблюдений выполнено разбиение данного изображения на 58 классов. Кроме того, в пакете приложено разбиение одного из фрагментов на 16 классов (рис. 1, *c, d*), 14 из которых — различные типы растительности, в частности 3 класса кукурузы и 3 сои, отличающиеся методиками возделывания почвы: *no-till* — вспашка не производится, *min-till* — вспашка с применением малоразрушающих технологий, *clear* — обычная вспашка. Задачей технологий *no-till* и *min-till* является минимальное воздействие на структуру почвы. Часть территории не размечена и далее в работе не рассматривается.

Сравнение карты наземных наблюдений с изображением показывает, что она значительно обобщена. Многочисленные небольшие особенности, визуально различимые на изображении, на карте не отмечены. Таким образом, не следует ожидать, что каждый пиксель определённой области будет отнесён к связанному с ней классу. Кроме того, карта в большей степени даёт классы использования земли вместо того, чтобы отражать классы покрывающей её растительности. Например, область, отмеченная как *Corn no-till*, действительно содержит участки голый почвы и остатки прошлогодней растительности, а всходы кукурузы из-за ранней даты регистрации изображения (12 июня) составляют только малый процент покрытия.

Расчёт усреднённых по пикселям соответствующих зон спектров отражения подтверждает вышеизложенное. Так, различные классы кукурузы и сои имеют близкие спектральные характеристики (рис. 2, *a, b*), однако внутри каждой из этих зон наблюдается существенный разброс значений. Среднеквадратичное отклонение (СКО) спектральных коэффициентов отражения $\sigma(\lambda)$ приведено на рис. 2, *c*.

При исследовании методов классификации ГС-данных для обучения использован фрагмент, представленный на рис. 1, *c*. На его основе (для каждого из методов) выполнено построение границ между областями, соответствующими выбранным классам, в многомерном пространстве признаков, сформированном из яркостей различных спектральных каналов. После этого осуществлялась классификация изображения (см. рис. 1, *a*). Эффективность методов классификации оценивалась как по разделимости классов в обучающей выборке, так и по точности классификации полного изображения. В последнем случае в качестве данных объективного контроля применялось имеющееся разбиение территории на 58 классов.

Классификация осуществлялась несколькими наиболее распространёнными методами. Напомним их суть.

Метод минимального расстояния (*MinDist*) определяет кластер, центр которого находится на минимальном евклидовом расстоянии от классифицируемого пикселя в многомерном пространстве признаков. Метод спектрального угла (*SAM* — *Spectral Angle Mapper*) [7] определяет кластер, для которого минимален угол между векторами, направленными из начала координат к центру кластера и к классифицируемому пикселю. Метод *SID* (*Spectral Information Divergence*) [8] основан на сравнении спектральных кривых эталона и классифицируемого пикселя путём расчёта дивергенции Кульбака — Лейблера.

Метод опорных векторов (*SVM*) [9] в отличие от вышеприведённых учитывает только ближайшие к разделяющей границе пиксели и формирует её таким образом, чтобы максимально увеличить расстояние от границы до классифицируемого объекта. Если найти поверхность, разделяющую пиксели классов, не удастся, учитывается количество пересечений классов (на основе расчёта суммы штрафов).

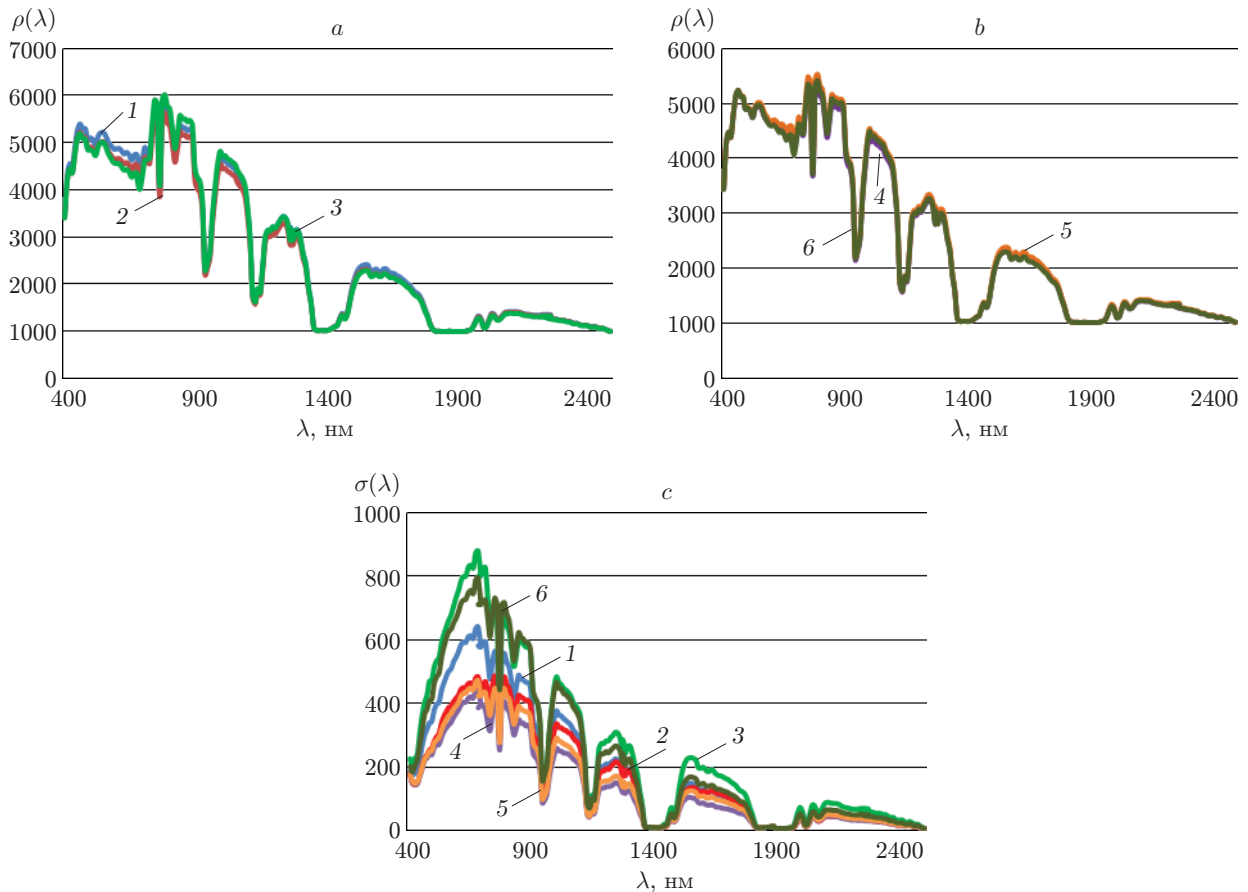


Рис. 2. Спектральные характеристики различных классов: *a* — кукурузы, *b* — сои, *c* — внутриклассовые разбросы спектральных коэффициентов отражения. Обозначения кривых: 1 — corn-no, 2 — corn-min, 3 — corn, 4 — soy-no, 5 — soy-min, 6 — soy

Методы классификации по расстоянию Махаланобиса (MahDist) и максимальному правдоподобию (ML) [10] основаны на определении плотности распределения пикселей обучающей выборки в выбранной системе признаков. При этом в качестве меры близости используется евклидово расстояние от классифицируемого пикселя до центра кластера, нормированное на СКО класса в данном направлении. Отсюда следует, что при равных расстояниях от классифицируемого пикселя до двух кластеров результат классификации определяет именно разброс данных. Основное различие этих методов состоит в том, что первый использует усреднённую по всем данным (коллективную) матрицу ковариации, а второй — собственную для каждого класса.

Эффективность разделения обучающих данных (фрагмента изображения) различными методами классификации представлена в табл. 1. Здесь точность — доля верно классифицированных пикселей. В последнем столбце в целях определения относительной трудоёмкости алгоритмов приведено время, необходимое для выполнения классификации на компьютере с процессором IntelCore2 Duo.

Для корректного исследования методов классификации, учитывающих при обучении ковариацию данных и требующих значительного объёма выборок, из рассмотрения исключены 4 класса, содержащие менее 200 точек (54, 26, 20 и 95 пикселей), или $\sim 2\%$ размеченной области фрагмента. Таким образом, оценка эффективности разделения данных осуществлялась по 12 классам, при этом на полном изображении дополнительно выполнено объединение 3 подклассов кукурузы и 3 подклассов сои, т. е. используется 8 комбиниру-

Таблица 1

**Эффективность классификации
фрагмента изображения природной зоны**

Методы классификации	Точность, %	Время обработки, с
MinDist	37,9	3
SAM	43,0	3
SID	51,0	3
SVM	85,7	120
MahDist	79,2	15
ML	99,9	15

ванных классов. Результаты оценки эффективности классификации полного изображения представлены в табл. 2.

Анализ полученных результатов показывает, что точность разделения обучающих данных для методов, не учитывающих распределение классов, находится на низком уровне (MinDist, SAM, SID), методы опорных векторов и расстояния Махаланобиса оказываются эффективнее, метод же максимального правдоподобия практически полностью разделяет обучающие выборки. Однако при классификации полного изображения результаты существенно хуже, что свидетельствует о значительной спектральной изменчивости различных культур по изображению. При этом методы опорных векторов и максимального правдоподобия уступают классификации по расстоянию Махаланобиса. Причина этого состоит в малом количестве точек обучающих выборок. Согласно [10] для корректной работы статистических методов необходимо, чтобы размер выборки по каждому классу превосходил количество спектральных каналов, как минимум, на порядок. Классификация по расстоянию Махаланобиса в этом плане наименее уязвима (что мы и наблюдаем), поскольку основывается на усреднённой по всем классам ковариационной матрице.

Для достижения указанного требования могут быть использованы два пути: увеличение размера выборок и уменьшение количества признаков. Первый ведёт к повышению трудоёмкости процедур и к тому же не всегда возможен при решении многих прикладных задач. Второй практичнее, однако при неудачном выборе признаков может привести к потере информации, определяющей различие классов.

Рассмотрим зависимость эффективности классификации ГС-данных от количества используемых спектральных каналов. В качестве способов выбора спектральных каналов применимы: регулярное прореживание, метод главных компонент (РСА) и метод главных

Таблица 2

**Эффективность классификации
полного 200-канального изображения природной зоны**

Методы классификации	Точность, %	Время обработки, мин
MinDist	33,9	6
SAM	40,5	7
SID	43,1	7
SVM	50,5	120
MahDist	56,3	22
ML	52,0	22




Рис. 3. Точность классификации обучающих выборок при различном количестве признаков: методами MahDist (a) и SVM (b). Кривые 1 — регулярное прореживание, 2 — PCA, 3 — MNF

компонент с предварительной нормализацией шума [11] (MNF — Minimum Noise Fraction Transform).

На рис. 3 приведены зависимости эффективности разделения обучающих выборок от количества признаков для методов классификации SVM и MahDist. Видно, что наиболее эффективные системы признаков формируются при применении MNF. При этом использование более 20 признаков для данного изображения является нецелесообразным.

На рис. 4 представлены результаты классификации полного изображения с применением метода MinDist и трёх наиболее эффективных методов при различном количестве спектральных признаков, выбранных регулярным прореживанием, PCA и MNF.

При сокращении размерности пространства признаков простым регулярным прореживанием наблюдается постепенное уменьшение эффективности классификации по расстоянию Махаланобиса. Для методов SVM и MinDist эффективность слабо зависит от количества признаков (вплоть до 10). Сокращение же признаков при использовании ML позволяет не только на 20 % повысить эффективность процедуры классификации, но и снизить её трудоёмкость более чем на два порядка. Так, лучшие результаты достигнуты с учётом всего лишь 5 признаков PCA. В этом случае (как и при разделении обучающей выборки по полному набору спектральных признаков) наиболее эффективными оказываются методы ML и SVM. Таким образом, при анализе изображений плохо различимых типов растительности (с близкими средними значениями для разделяемых классов и с высоким внутриклассовым разбросом) целесообразно использовать ГС-данные для выбора небольшого количества информативных признаков с последующим применением методов статистической классификации. При этом, если для методов ML и MahDist эффективность практически не зависит от сравниваемых способов выбора признаков, то для методов SVM и MinDist наиболее эффективным является способ MNF.

Классификация типов подстилающей поверхности по гиперспектральным изображениям антропогенных зон. Исследование эффективности методов классификации данных ДЗЗ антропогенных зон проводилось на примере обработки авиационного ГС-изображения Национальной аллеи в историческом центре Вашингтона. Размер изображения 307×1208 пикселей, 191 канал в диапазоне 0,4–2,4 мкм (каналы в диапазоне поглощения воды 0,9–1,4 мкм исключены). На рис. 5, a представлен RGB-композит (каналы 60, 27, 17) данного изображения.

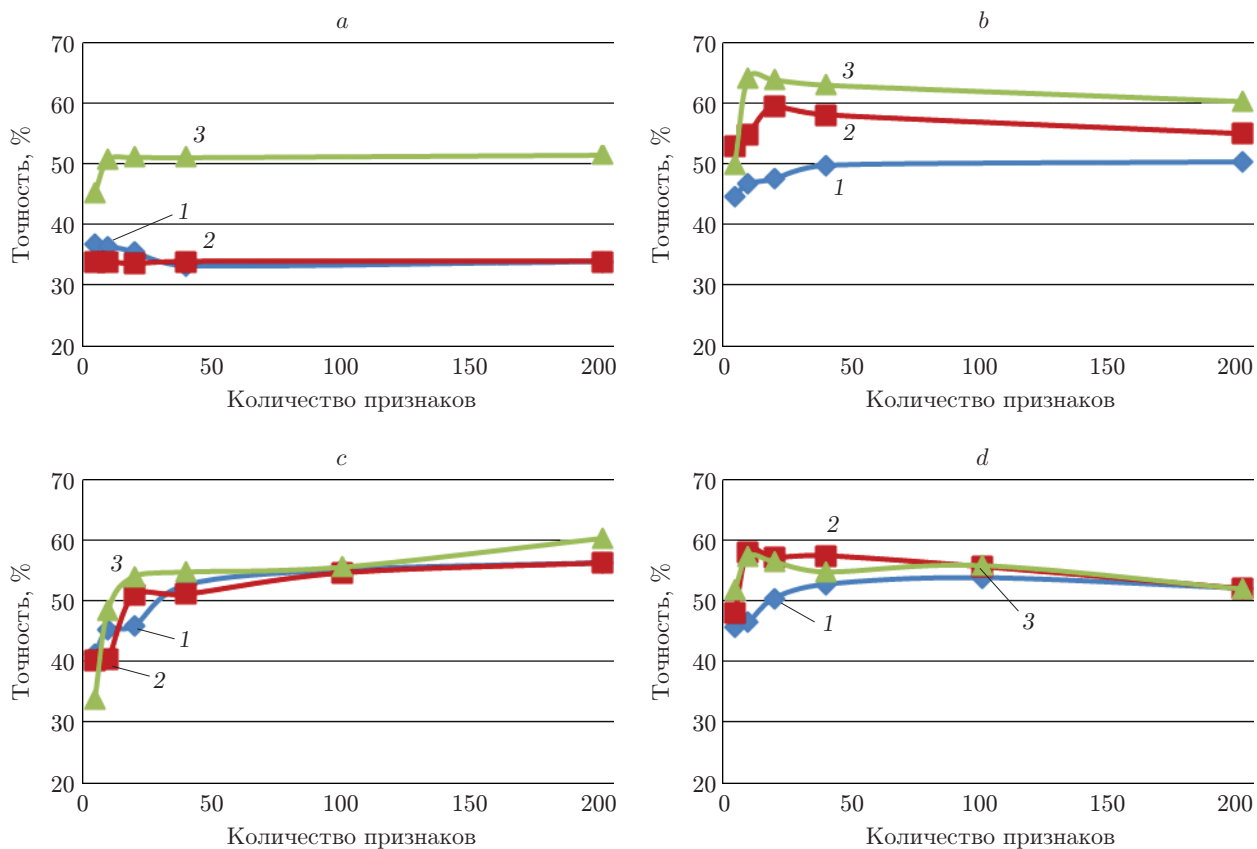


Рис. 4. Эффективность классификации природной зоны при разном количестве признаков: методами MinDist (a), SVM (b), MahDist (c), ML (d). Обозначения кривых см. на рис. 3




Рис. 5. Классификация антропогенных зон: a — RGB-композит изображения, b — RGB-композит фрагмента изображения с областями контрольной выборки, c — результат классификации

Таблица 3

**Точность классификации контрольной выборки
изображения антропогенной зоны при различном количестве каналов**

n	MinDist			SVM			MahDist			ML		
	Прореживание	PCA	MNF	Прореживание	PCA	MNF	Прореживание	PCA	MNF	Прореживание	PCA	MNF
2	93,3	89,7	69,1	94,8	92,8	67,2	93,5	91,1	68,6	95,6	94,8	73,7
5	95,0	94,5	85,9	95,4	95,5	89,3	84,9	92,8	78,1	96,5	93,8	87,2
10	95,2	94,5	90,6	93,7	95,6	96,2	83,0	85,9	87,2	94,7	89,3	90,1
40	94,5	94,6	87,7	93,9	96,4	93,0	85,6	85,6	84,5	88,5	84,9	86,4
100	94,6	94,6	82,3	93,8	94,4	88,0	89,8	83,7	84,9	79,1	77,1	80,3

На изображении показаны здания с крышами разного типа, автомобильные дороги, пешеходные дорожки, газоны в различном состоянии, отдельные деревья и участки с плотной древесной растительностью, водная поверхность. Основные классы визуально легко различимы. К сожалению, соответствующая данному участку местности карта наземных наблюдений отсутствует, однако имеется контрольная выборка с разбиением на 7 классов: вода, газон, дорога, крыши, тень, лес, дорожка. Расположение областей контрольной выборки для центрального фрагмента представлено на рис. 5, *b*.

Для обучения классификатора использованы зоны изображения 13 классов. Из них 5 относились к типам крыш, 4 — к газонам, по одному к древесной растительности, водной поверхности, дорожкам и тени.

Результаты оценки эффективности различных методов классификации (при разных способах сокращения размерности пространства признаков) по контрольной выборке приведены в табл. 3 (n — количество используемых каналов). Видно, что при правильном выборе признаков каждый из исследуемых методов достигает точности классификации 93–97 %.

Лучшая точность классификации контрольной выборки достигнута с применением метода максимального правдоподобия по 5 компонентам, выбранным регулярным прореживанием. Результат классификации полного изображения этим методом и был использован в дальнейшем в качестве эталонной карты классов (рис. 5, *c*).

На рис. 6 представлены зависимости точности классификации полного изображения с применением методов MinDist, SVM, ML и MahDist при различном количестве спектральных признаков, выбранных тремя способами: регулярным прореживанием, на основе PCA и на основе MNF. В отличие от результатов, полученных при обработке изображений природных территорий, в данном случае классификация по минимальному расстоянию не уступает статистическим методам.

Точность классификации рассматриваемого изображения для всех методов имеет слабую зависимость от количества признаков. Эффективность выбора признаков регулярным прореживанием в целом близка к эффективности PCA. Выбор же признаков на основе MNF уступает в связи с неверной оценкой уровня шума каналов. Это связано с тем, что оценка шума выполняется по уровню высокочастотной составляющей сигнала, а на изображении антропогенных зон имеется большое количество резких перепадов яркости. В результате первые компоненты MNF оказываются низкоинформативными.

Классификация типов подстилающей поверхности при совместном использовании спектральных и пространственных признаков. При гиперспектральной

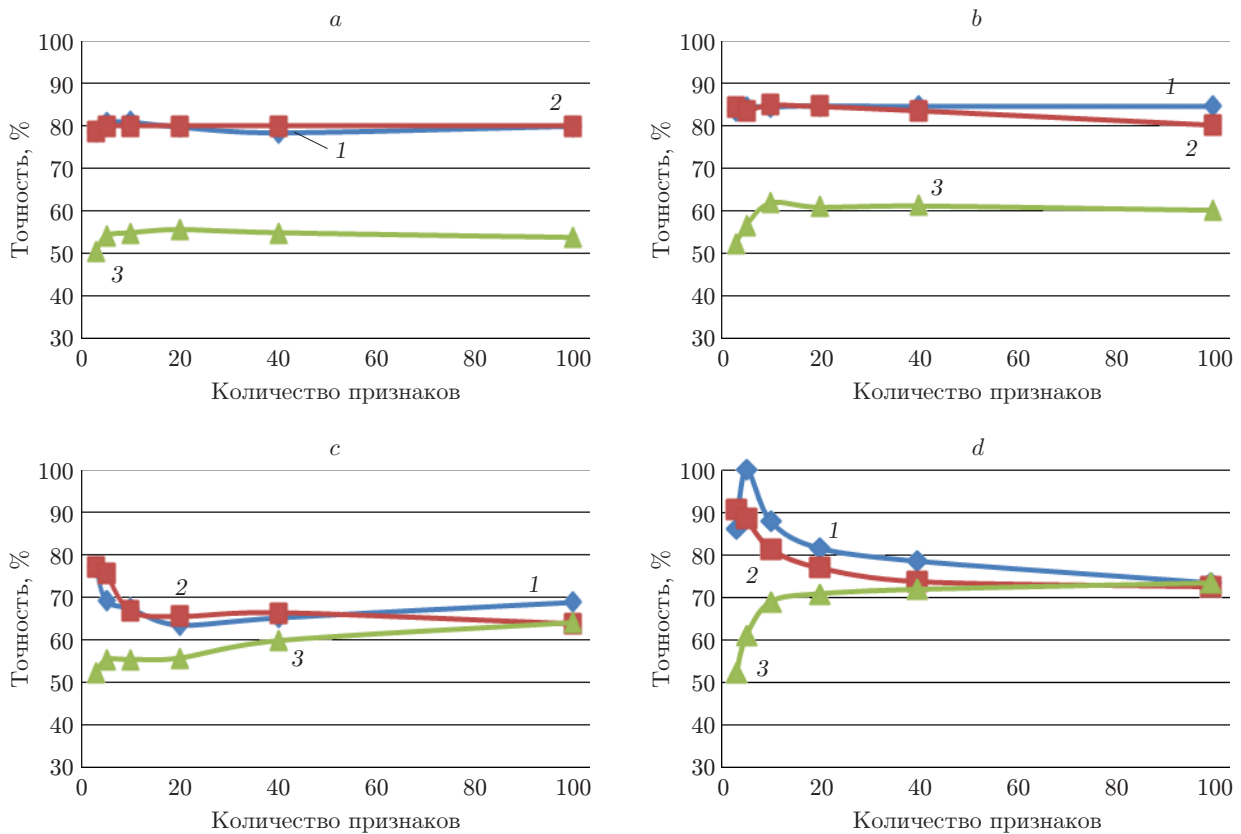


Рис. 6. Эффективность классификации антропогенной зоны при разном количестве признаков: методами MinDist (a), SVM (b), MahDist (c), ML (d). Обозначения кривых см. на рис. 3

сѐмке поверхности Земли изображения большинства объектов оказываются неоднородными, несмотря на то что соседние пиксели с большой долей вероятности относятся к одному и тому же классу (как правило, сцена состоит из однородных регионов). Во-первых, спектральный состав пикселя является комбинацией спектральных характеристик объектов, образующих этот пиксель. Во-вторых, отдельные участки поверхности оказываются в разных условиях. Одни освещены прямым солнечным излучением, другие находятся в тени и освещаются отражѐнным или рассеянным светом. Кроме того, они имеют различную ориентацию поверхности по отношению к источнику освещения. К значительным искажениям результирующего спектра также приводит переотражение между слоями. Перечисленные выше методы классификации рассматривают обрабатываемые данные не как изображения, а как совокупность независимых спектральных измерений и эти факты не учитывают.

Для решения проблемы целесообразно применять одновременный анализ спектральных и пространственных признаков [12]. В частности, широкое распространение получили методы, осуществляющие предварительную сегментацию изображения (деление его на однородные в физическом плане области). Далее каждый сегмент (область) рассматривается как отдельный объект и выполняется его классификация на основе выбора доминирующего класса (методом голосования) в карте попиксельной спектральной классификации. Подобный подход в последнее десятилетие активно развивается и является наиболее перспективным для обработки данных гиперспектральной сѐмки [13]. Блок-схема одного из методов спектрально-пространственной классификации приведена на рис. 7. Эффективность такого подхода в значительной степени определяется корректностью выполнения



Рис. 7. Блок-схема спектрально-пространственной классификации

Таблица 4

Точность классификации фрагмента изображения при различных размерах фильтра предварительной обработки

Методы классификации	Без фильтра	3 × 3	5 × 5	7 × 7	9 × 9
SVM (Lin)	76,7	84,9	91,4	92,1	91,7
SVM (RBF)	70,8	83,6	88,0	89,7	89,8

процедуры предварительной сегментации данных ДЗЗ, которая затруднена при обработке изображений природных территорий среднего и высокого разрешения (особенно с трудно-различимыми классами растительности).

В качестве альтернативы может быть применён подход, не использующий предварительную сегментацию и заключающийся в классификации каждого пикселя на основе анализа его окрестности [14]. В этом случае с учётом пространственной связности значения соседних пикселей рассматриваются как гипотезы при уточнении значения центрального пикселя, причём существуют различные способы выбора наиболее достоверной из имеющихся гипотез. В простейшем случае на этапе предварительной обработки может применяться медианное сглаживание. В табл. 4 приведена точность классификации фрагмента изображения (см. рис. 1, *d*) методом SVM на основе линейных (Lin) и радиально-базисных разделяющих функций (RBF) по 10 главным компонентам с предварительной медианной фильтрацией исходных данных. Для обучения в этом случае использовалась случайная выборка пикселей каждого класса (15 значений для классов, представленных на изображении малым количеством пикселей, и 50 — большим).

Видно, что процедура предобработки позволила повысить точность классификации фрагмента приблизительно на 15%. Для дальнейшего повышения эффективности обработки гипер- и мультиспектральных изображений представляется перспективным развитие рассмотренного подхода в части сочетания выбора наиболее информативных признаков и анализа 3D-окрестностей пикселей (по спектральной и двум пространственным координатам) в целях определения наиболее вероятной гипотезы.

Заключение. В предлагаемой работе выполнены сравнительные исследования эффективности ряда методов классификации гиперспектральных изображений при различении типов подстилающей поверхности природных и антропогенных зон.

Установлено, что лучшая точность контролируемой классификации трудноразличимых типов растительности достигается при применении методов, учитывающих оценку

функции плотности вероятности распределения эталонных классов (Махаланобиса и максимального правдоподобия). Однако это требует значительного объёма обучающих выборок. В случае же недостаточного объёма обучающих данных целесообразно использовать метод опорных векторов.

Показано, что при обработке ГС-изображений природных территорий имеет смысл применять небольшое количество признаков (10–20), выделенных методом главных компонент с нормализацией шума каналов. Его реализация позволила повысить эффективность классификации растительности на 10 %, снизив трудоёмкость на два порядка.

При обработке ГС-изображений антропогенных территорий классификация по минимальному расстоянию не уступает статистическим методам, а наибольшую эффективность демонстрируют методы максимального правдоподобия и опорных векторов. При этом точность классификации для всех методов имеет слабую зависимость от количества признаков. Эффективность признаков, выбранных с применением регулярного прореживания и PCA, в целом близка. Выбор же признаков на основе MNF уступает по причине неверной оценки уровня шума каналов.

Преимущество ГС-данных по сравнению с мультиспектральными состоит в возможности выбора небольшого количества информативных признаков для каждой задачи мониторинга поверхности Земли и околоземного пространства с учётом типа сцены. Методика же формирования такой системы представляет собой отдельную серьёзную проблему.

Дальнейшее повышение эффективности обработки целесообразно осуществлять за счёт совместного применения пространственных и спектральных признаков. При этом могут рассматриваться подходы, как основанные на сегментации изображений и определении доминирующего класса в полученных сегментах, так и сочетающие процедуры анализа 3D-окрестностей пикселей с выбором наиболее информативных спектральных признаков.

СПИСОК ЛИТЕРАТУРЫ

1. **Остриков В. Н., Плахотников О. В., Кириенко А. В.** Обработка гиперспектральных данных, получаемых с авиационных и космических носителей // *Современные проблемы дистанционного зондирования Земли из космоса*. 2013. **10**, № 2. С. 243–251.
2. **Chan T. H., Ambikapathi A., Ma W. K., Chi C. Y.** Robust affine set fitting and fast simplex volume max-min for hyperspectral endmember extraction // *IEEE Trans. Geosci. and Remote Sensing*. 2013. **51**, Is. 7. P. 3982–3997.
3. **Cawse-Nicholson K., Damelin S. B., Robin A., Sears M.** Determining the intrinsic dimension of a hyperspectral image using random matrix theory // *IEEE Trans. Image Process.* 2013. **22**, Is. 4. P. 1301–1310.
4. **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.
5. **Борзов С. М., Потатуркин О. И.** Классификация типов растительного покрова по гиперспектральным данным дистанционного зондирования Земли // *Вестн. НГУ. Сер. Информационные технологии*. 2014. № 4. С. 13–22.
6. **Потатуркин О. И., Борзов С. М., Потатуркин А. О., Узилов С. Б.** Методы и технологии обработки мульти- и гиперспектральных данных дистанционного зондирования Земли высокого разрешения // *Вычислительные технологии*. 2013. **18**, Спец. вып. С. 53–60.
7. **Kruse F. A., Lefkoff A. B., Boardman J. B. et al.** The Spectral Image Processing System (SIPS) — interactive visualization and analysis of imaging spectrometer data // *Remote Sensing of Environment*. 1993. **44**, N 2–3. P. 145–163.

8. **Du H., Chang C., Ren H. et al.** New hyperspectral discrimination measure for spectral characterization // Opt. Eng. 2004. **43**, N 8. P. 1777–1786.
9. **Joachims T.** Making large-scale support vector machine learning practical // Advances in Kernel Methods — Support Vector Learning /Eds. B. Schoelkopf, C. J. C. Burges, A. J. Smola. Cambridge, USA: MIT Press, 1999. P. 169–184.
10. **Richards J. A.** Remote Sensing Digital Image Analysis. Berlin: Springer-Verlag, 2013. 494 p.
11. **Green A. A., Berman M., Switzer P., Craig M. D.** A transformation for ordering multispectral data in terms of image quality with implications for noise removal // IEEE Trans. Geosci. and Remote Sensing. 1988. **26**, N 1. P. 65–74.
12. **Plaza A., Benediktsson J. A., Boardman J. W. et al.** Recent advances in techniques for hyperspectral image processing // Remote Sensing of Environment. 2009. **113**, Suppl. 1. P. 110–122.
13. **Бондур В. Г.** Современные подходы к обработке больших потоков гиперспектральной и многоспектральной аэрокосмической информации // Исследование Земли из космоса. 2014. № 1. С. 4–16.
14. **Chen C., Li W., Tramel E. W. et al.** Spectral-spatial preprocessing using multihypothesis prediction for noise-robust hyperspectral image classification // IEEE Journ. Sel. Top. Appl. Earth Observ. Remote Sens. 2014. **7**, Is. 4. P. 1047–1059.

Поступила в редакцию 2 февраля 2015 г.
