

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 528.72 : 004.93

ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ СПЕКТРАЛЬНО-ПРОСТРАНСТВЕННОЙ КЛАССИФИКАЦИИ ДАННЫХ ГИПЕРСПЕКТРАЛЬНЫХ НАБЛЮДЕНИЙ*

С. М. Борзов¹, О. И. Потатуркин^{1,2}

¹Институт автоматизации и электрометрии СО РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 1

²Новосибирский государственный университет,
630090, г. Новосибирск, ул. Пирогова, 2

E-mail: borzov@iae.nsk.su

potaturkin@iae.nsk.su

Экспериментально исследована эффективность методов спектрально-пространственной классификации трудноразличимых типов растительности по гиперспектральным данным дистанционного зондирования Земли, учитывающих при анализе пикселей изображений их локальные окрестности. Рассмотрены алгоритмы, использующие предварительную пространственную обработку исходных данных, а также постобработку картосхем попиксельной спектральной классификации. Приведены результаты, полученные как на крупноформатном гиперспектральном изображении, так и на его тестовом фрагменте при различных способах формирования обучающих выборок. Точность классификации во всех случаях оценена путём сопоставления подспутниковых данных и картосхем классов, сформированных с помощью сравниваемых методов. При обсуждении результатов поясняются причины, приводящие к различию оценок.

Ключевые слова: дистанционное зондирование Земли, гиперспектральные изображения, фрагменты, спектральные и пространственные признаки, классификация типов подстилающих поверхностей.

DOI: 10.15372/AUT20170105

Введение. В настоящее время дистанционное зондирование Земли — наиболее активно развивающаяся область науки и техники. В значительной степени это обусловлено появлением новых технических средств получения, передачи, хранения и обработки больших массивов данных. В частности, при решении практических задач всё чаще используются гиперспектральные (ГС) спутниковые изображения, отличительные особенности которых — узкая ширина и сотни спектральных каналов. Такие изображения потенциально обладают большими возможностями при обнаружении и распознавании различных объектов, однако требуют создания специализированных технологий обработки данных.

При гиперспектральной съёмке поверхности Земли регистрируемые изображения получаются неоднородными несмотря на то, что соседние пиксели, как правило, относятся к одному и тому же классу (сцена состоит преимущественно из однородных регионов). Во-первых, участки поверхности находятся в разных условиях. Одни освещены прямым солнечным излучением, другие оказываются в тени и освещаются отражённым или рассеян-

*Работа выполнена при поддержке Президиума РАН (комплексная программа фундаментальных исследований Сибирского отделения РАН № П.2П «Интеграция и развитие» в составе программ РАН, проект № П.2П/П.10-1).

ным светом [1]. Во-вторых, они имеют различную ориентацию поверхности по отношению к источнику освещения и соответственно отличающиеся коэффициенты отражения. К значительным искажениям результирующего спектра также приводит переотражение между слоями (листва—почва, вода—почва и т. п.). Кроме того, спектральный состав каждого пикселя определяется характеристиками объектов, образующих данный пиксель [2]. По этой причине картосхемы, полученные в результате попиксельной спектральной классификации, оказываются раздробленными и содержат большое количество ложно классифицированных пикселей.

Решить указанную проблему позволяет совместный анализ спектральных и пространственных признаков ГС-изображений [3–6]. Могут быть использованы два подхода. Первый основан на предварительной пространственной обработке с целью уточнения значения каждого пикселя с учётом значений пикселей в его локальной окрестности [7–13] и последующей спектральной классификации полученных данных. Второй заключается в первоначальной попиксельной спектральной классификации и затем в пространственной обработке сформированных картосхем с отнесением каждого пикселя к наиболее часто встречающемуся (доминирующему) классу в определённой окрестности.

И в том и в другом случае окрестность либо задаётся заранее (например, прямоугольное окно), либо формируется в процессе сегментации. Отметим, что методы, основанные на сегментации, получили широкое распространение и в настоящее время считаются самыми перспективными для обработки данных гиперспектральной съёмки [14]. Их эффективность в значительной степени определяется корректностью выполнения процедуры предварительной обработки изображений, поэтому в ряде публикаций предлагаются и рассматриваются различные алгоритмы спектрально-пространственной классификации, отличающиеся в первую очередь реализацией этого этапа [15].

Достоверную оценку эффективности предлагаемых методов классификации ГС-изображений можно получить только на основе сопоставления результатов обработки реальных данных дистанционного зондирования Земли и картосхем 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. Это является существенным сдерживающим фактором совершенствования указанных вычислительных технологий.

Во многих работах оценка эффективности методов классификации осуществляется по небольшим тестовым фрагментам [16–19]. В качестве обучающей выборки, как правило, используется случайный набор пикселей каждого класса, а в качестве контрольной — все оставшиеся. Такой подход позволяет оперативно получить оценку эффективности исследуемых методов, однако её объективность вызывает определённые сомнения. Это связано с тем, что для обеспечения приемлемого качества классификации минимальный объём обучающей выборки для параметрических методов составляет порядка $10k$ точек на каждый класс (где k — число признаков), для непараметрических — $50k$ точек. При малых размерах обрабатываемых фрагментов обеспечить выполнение указанных требований не удаётся.

Цель предлагаемой работы — экспериментальные исследования эффективности методов контролируемой спектрально-пространственной классификации с использованием как тестового фрагмента, так и всего крупноформатного гиперспектрального изображения. Точность классификации в обоих случаях оценивается путём сопоставления подспутниковых данных и картосхем классов, сформированных сравниваемыми методами.

Алгоритмы спектрально-пространственной классификации. Предлагаемое исследование является продолжением [20, 21], где на примере обработки тестовых ГС-изображений экспериментально сравнивается эффективность ряда методов попиксельной

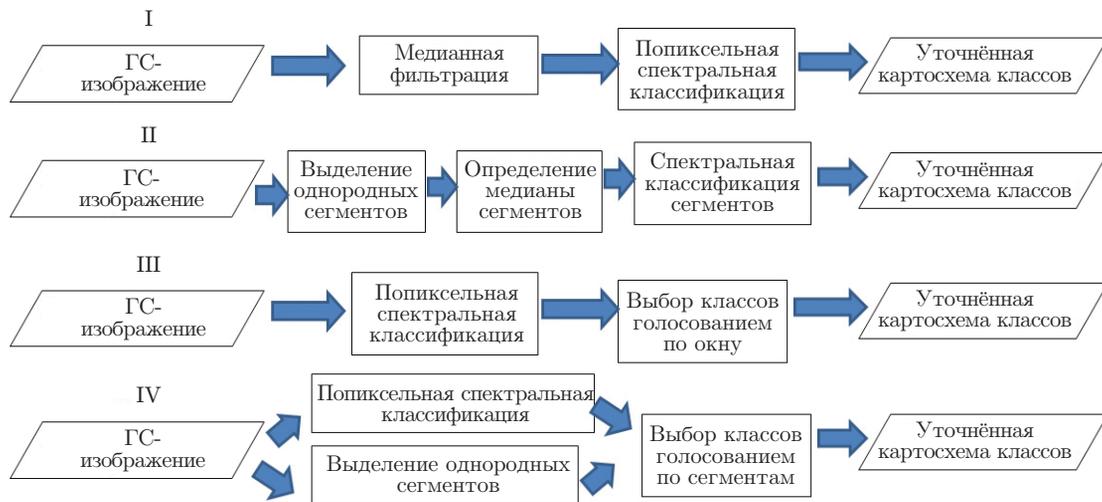


Рис. 1. Спектрально-пространственная классификация с включением в анализ информации о ближайшей окрестности на предварительном и заключительном этапах

спектральной классификации трудноразличимых типов растительности. Показано, что лучшие результаты достигаются с применением метода опорных векторов, а для анализа целесообразно использовать небольшое количество признаков (10–20), выделенных методом главных компонент с нормализацией шума каналов [22].

Исследуется эффективность методов спектрально-пространственной классификации, учитывающих при анализе пикселей ГС-изображений их локальные окрестности. Рассматриваются конкретные алгоритмы, реализующие эти методы и применяющие как пространственную предобработку исходных данных, так и постобработку картосхем попиксельной спектральной классификации путём выбора наиболее часто встречающегося класса, в результате чего определяются уточнённые картосхемы (рис. 1). В качестве анализируемой окрестности используется либо прямоугольное окно, либо сегменты, сформированные из близких по параметрам пикселей.

Кратко охарактеризуем каждый из сравниваемых алгоритмов.

Алгоритм I. Выполняется уточнение значений пикселей исходного ГС-изображения путём двумерной медианной фильтрации по прямоугольному окну в каждом спектральном канале, а затем проводится попиксельная спектральная классификация сформированного ГС-изображения.

Алгоритм II. Выполняется разбиение (основанное на выделении границ) изображения на однородные области с параметрами, обеспечивающими заведомо избыточное число сегментов. Далее вычисляются поканальные медианные значения внутри каждого сегмента и по полученным значениям осуществляется их спектральная классификация.

Алгоритм III. Выполняются попиксельная спектральная классификация, а затем мажоритарная обработка [23] сформированной картосхемы с присвоением каждому пикселю номера класса, которому принадлежит большая часть окружающих его пикселей. Таким образом выявляется доминирующий класс в результате голосования пикселей по прямоугольному окну.

Алгоритм IV. Выполняются избыточная сегментация и независимо попиксельная спектральная классификация. Далее в сформированной картосхеме внутри каждого сегмента находится наиболее часто встречающийся класс, номер которого присваивается всем его пикселям (класс определяется в результате голосования пикселей по сегменту).

Эффективность классификации оценивается путём сопоставления уточнённых картосхем классов, сформированных с применением перечисленных алгоритмов, и подспутнико-

вых данных. В качестве критерия используется результирующая точность классификации (overall accuracy), определяемая как выраженное в процентах отношение количества верно классифицированных пикселей к их общему количеству.

Исходные данные. Исследование эффективности спектрально-пространственной классификации выполнено на примере обработки крупноформатного ГС-изображения (рис. 2, *a*), полученного в рамках программы AVIRIS (Airborne Visible Infrared Imaging Spectrometer) на опытном полигоне «Индиан Пайс» (штат Индиана, США). Размер изображения равен 614×2677 пикселей, разрешение — 20 м/пиксель, число каналов — 220 в диапазоне 0,4–2,5 мкм, по результатам наземных наблюдений изображение разбито на 58 классов (эталонная карта классов, рис. 2, *b*). Среди них присутствуют сельскохозяйственные культуры (в том числе 15 классов кукурузы и 18 сои, отличающиеся методиками возделывания почвы), а также магистраль, железная дорога, лес, жилые постройки. Кроме того, имеется разбиение одного из фрагментов на 16 классов (рис. 2, *c, d*), 14 из которых представляют собой различные типы растительности, в том числе 3 класса кукурузы и 3 сои. Часть территории не размечена и далее в работе не рассматривается.

Сравнение карты классов наземных наблюдений с исходным изображением показывает, что многочисленные небольшие особенности, визуально различимые на изображении, на ней не отмечены. Следует также учитывать, что карта в большей степени определяет способ использования земли, а не классы покрывающей её растительности, которая из-за ранней даты регистрации (12 июня) занимает малый процент площади. Кроме того, на крупноформатном изображении можно видеть значительную спектральную изменчивость отдельных культур на различных его участках. Расчёт усреднённых по пикселям соответствующих зон спектров отражения подтверждает вышеизложенное. Так, классы кукурузы и сои имеют близкие спектральные характеристики, однако внутри каждой из этих зон наблюдается существенный разброс значений. Среднеквадратичное отклонение спектральных коэффициентов отражения в информативных диапазонах более чем на порядок

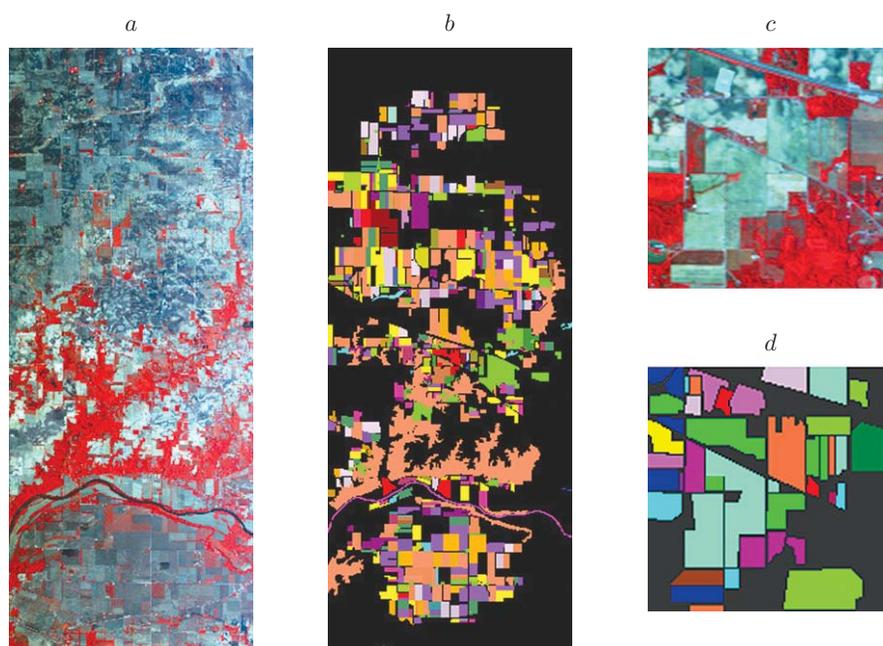


Рис. 2. Исходные данные для исследования эффективности методов классификации: *a* — *RGB*-композит (каналы 40:20:10) крупноформатного ГС-изображения, *b* — эталонная карта классов изображения, *c* — *RGB*-композит фрагмента, *d* — эталонная карта классов фрагмента

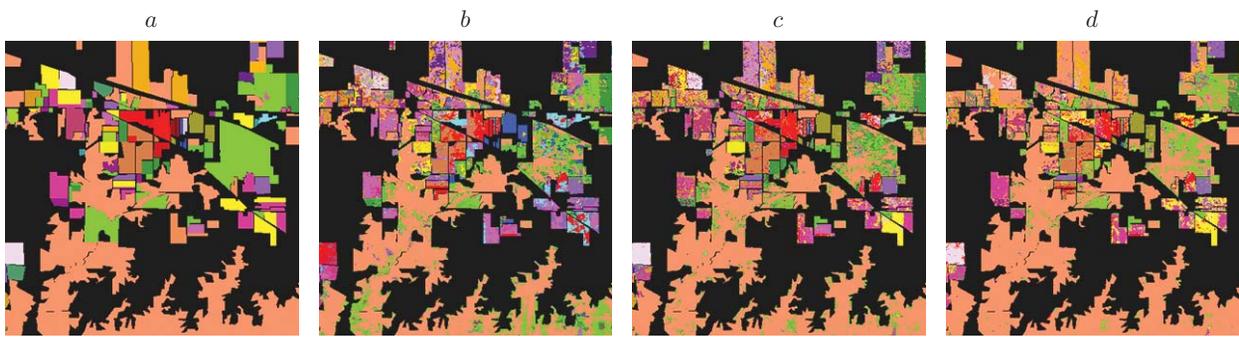


Рис. 3. Спектральная классификация ГС-изображения по 20 признакам: *a* — эталонная карта классов; *b, c, d* — картосхемы классов, сформированные методами MinDist, ML и SVM

превышает разброс средних значений для классов [20]. Интегральная разделяемость классов, оценённая как доля верно классифицированных пикселей при использовании метода максимального правдоподобия (с обучением по всем данным), на фрагменте составляет 99,88 %, а на крупноформатном изображении — лишь 76,25 %. Представленные выше сведения необходимо учитывать для верной оценки полученных далее результатов.

Прежде чем приступить к исследованию эффективности спектрально-пространственной классификации, продемонстрируем, что даёт обработка данных гиперспектральной съёмки в сравнении с мультиспектральной. С этой целью сформируем из ГС-изображения (см. рис. 2, *a*) мультиспектральное путём усреднения каналов в соответствии со спектральными диапазонами аппаратуры ЕТМ спутника «Ландсат» и сравним результаты их классификации.

Обучающая выборка (ОВ) в данном эксперименте формировалась из крупноформатного изображения с применением случайного выбора 25 % пикселей каждого класса (1500 пикселей в среднем на класс). При этом подклассы кукурузы и сои были объединены в класс кукуруза и класс соя. Таким образом, оценка точности осуществлялась по 28 классам. Классификация выполнялась с помощью трёх методов: минимального расстояния (MinDist), максимального правдоподобия (ML) и опорных векторов (SVM) — с использованием для ГС-изображений 10 и 20 наиболее информативных спектральных признаков, выделенных методом главных компонент с предварительной нормализацией шума (MNF). На рис. 3 представлены эталонная карта классов и картосхемы классов для центральной области изображения. Полученные оценки точности классификации приведены в табл. 1. Из неё следует, что классификация ГС-изображения эффективнее мультиспектрального примерно на 10 %, при этом лучшие результаты как для гиперспектральных, так и для мультиспектральных данных достигаются методом SVM.

На рис. 4 дана зависимость точности классификации крупноформатного ГС-изображения методом SVM от количества признаков при различных объёмах ОВ: 20 пикселей каждого класса ($\sim 0,3$ %), 10 и 25 % пикселей каждого класса.

Анализ результатов показывает, что сделанные в [21] выводы о достаточности для

Таблица 1

Эффективность классификации мультиспектральных и ГС-изображений различными методами

Типы данных	MinDist (%)	ML (%)	SVM (%)
«Ландсат» (6 каналов)	44,6	53,9	67,5
AVIRIS (10 MNF)	50,4	67,6	74,4
AVIRIS (20 MNF)	52,9	72,5	76,3

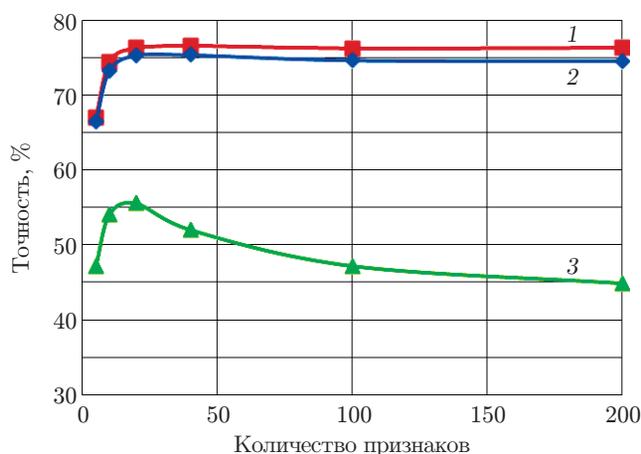


Рис. 4. Зависимость точности классификации от количества признаков для различных обучающих выборок (кривые 1, 2 — ОБ содержит 25 и 10 % пикселей каждого класса соответственно, кривая 3 — 20 пикселей каждого класса)

классификации типов растительности 10–20 признаков и эффективности метода SVM при указанных способах формирования ОБ также верны. Исходя из этого, на всех этапах исследований попиксельная спектральная классификация выполнялась методом SVM по 20 признакам, выбранным методом MNF.

Исследование эффективности спектрально-пространственной классификации фрагмента крупноформатного изображения. На первом этапе эффективность перечисленных алгоритмов спектрально-пространственной классификации оценивалась на примере обработки фрагмента ГС-изображения. При обучении по выборке, сформированной случайным образом из пикселей каждого класса (для классов, представленных большим количеством пикселей, — по 50, малым — по 15), попиксельная спектральная классификация данного фрагмента обеспечила точность 79,9 %. Результаты, достигнутые с применением алгоритмов, учитывающих при анализе пикселей ГС-изображений их локальные окрестности, представлены в табл. 2. При выполнении алгоритмов I и III принципиальным является размер окна обработки. Приведены значения результирующей точности классификации при различных значениях этого параметра. В алгоритмах II и IV предполагается использование пред- и постобработки по сегментам соответственно. В данных исследованиях намеренно не применялся визуальный контроль качества выполнения сегментации, поскольку на практике при автоматической классификации такая возможность отсутствует. Параметры алгоритма сегментации, основанного на выделении связанных границ, обес-

Таблица 2

Эффективность спектрально-пространственной классификации фрагмента изображения

Классификация с учётом окна	Размер окна			
	3 × 3	5 × 5	7 × 7	9 × 9
С предварительным усреднением по окну (I)	84,9	91,4	92,1	91,7
С постобработкой голосованием по окну (III)	83,5	86,0	86,9	87,5
Классификация с учётом сегментов	Количество сегментов			
	176	361	730	1283
С предварительным усреднением по сегментам (II)	91,2	93,3	92,9	91,3
С постобработкой голосованием по сегментам (IV)	89,3	90,0	88,6	88,1

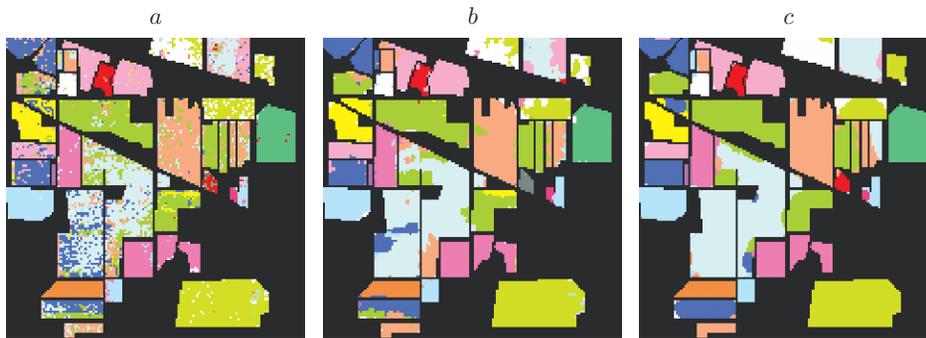


Рис. 5. Результаты обработки фрагмента изображения: *a* — попиксельная SVM-классификация, *b* — SVM-классификация с последующим голосованием пикселей в сегментах картосхемы, *c* — предварительное усреднение по сегментам и SVM-классификация

печивали заведомо избыточное разбиение изображения. Для этой пары алгоритмов классификации принципиальной является средняя площадь образованных сегментов, поэтому во второй части табл. 2 приведены результаты при различной степени разбиения.

Представленные данные показывают, что все рассматриваемые алгоритмы позволяют повысить точность классификации фрагмента за счёт пространственных связей пикселей более чем на 10 %. При этом эффективнее оказываются процедуры, осуществляющие уточнение значений пикселей с учётом окрестности (прямоугольного окна или сегмента) на этапе предварительной обработки. Они обеспечивают точность до 93,3 % практически без подбора параметров обработки (изменение размера окрестности в диапазоне 25–50 пикселей незначительно влияет на результаты). При использовании алгоритмов III и IV эта величина не превышала 90 %. Однако точность алгоритма IV может быть несколько улучшена путём существенного усложнения способа сегментации (например, согласно [18] до 92,4 %, что практически соответствует полученным значениям для первой пары алгоритмов). На рис. 5 приведены примеры картосхем классов, сформированных с применением различных алгоритмов классификации.

Исследование эффективности спектрально-пространственной классификации крупноформатного изображения. Алгоритмы спектрально-пространственной классификации гиперспектральных данных на примере обработки крупноформатного изображения (см. рис. 2, *a*) исследовались с использованием пяти способов формирования обучающей выборки:

- для обучения применяются все пиксели фрагмента (см. рис. 2, *c*);
- из изображения случайным образом выбирается такое же количество пикселей каждого класса, что и при использовании фрагмента (~ 3 % пикселей);
- из изображения случайным образом выбирается равное количество пикселей (20 на класс) каждого класса;
- из изображения случайным образом выбирается 10 % пикселей каждого класса;
- из изображения случайным образом выбирается 25 % пикселей каждого класса.

Для сегментации изображения (алгоритмы II и IV) применялась прежняя процедура, основанная на выделении связных границ с параметрами, обеспечившими лучшие результаты классификации на фрагменте ГС-изображения. В качестве данных объективного контроля использовано имеющееся разбиение территории на 58 классов (см. рис. 2, *b*). Как и в предыдущем эксперименте, подклассы кукурузы и сои объединены в класс кукуруза и класс соя. Кроме того, при формировании ОБ первым и вторым способами для корректного исследования методов классификации из рассмотрения исключены классы, содержащие на фрагменте менее 200 точек, а также не представленные на нём вовсе. Таким образом,

Таблица 3

Классы на крупноформатном изображении при обучении по фрагменту

№ п/п	Классы	Количество пикселей на изображении	Количество пикселей на фрагменте (в ОВ)
1	Кукуруза	113766	2502
2	Трава	11587	497
3	Деревья	2331	747
4	Покос	2258	489
5	Соя	66135	4050
6	Пшеница	4979	212
7	Лес	63562	1294
8	Посёлок	17195	380
Всего пикселей		281813	10171

при формировании ОВ первым и вторым способами точность оценивалась по 8 классам (табл. 3), а в остальных случаях — по 28 классам.

Результаты спектрально-пространственной классификации крупноформатного изображения перечисленными выше алгоритмами представлены в табл. 4. Из неё следует, что в данном случае эффект привлечения пространственной информации оказывается существенно ниже, чем в экспериментах с фрагментом. Большую результативность демонстрируют алгоритмы, базирующиеся на сглаживании (уточнении значений пикселей) на этапе предварительной обработки, особенно по прямоугольным окнам (результатирующая точность повышается на 7–9 %). Методы, основанные на постобработке картосхем попик-

Таблица 4

Эффективность классификации крупноформатного изображения при различных ОВ

Алгоритмы классификации	Тип обучающей выборки				
	Фрагмент изображения	20 пикселей на класс (~0,3 %)	Объём как на фрагменте (~3 %)	10 % пикселей каждого класса	25 % пикселей каждого класса
Спектральная классификация (SVM)	64,1	55,5	70,5	75,3	76,3
С предварительным сглаживанием (I)	67,1	58,9	79,4	82,1	84,0
С предварительным усреднением по сегментам (II)	61,8	59,6	73,9	79,4	81,4
С постобработкой голосованием по окрестности (III)	66,6	57,6	72,2	77,5	78,9
С постобработкой голосованием по сегментам (IV)	63,8	55,2	68,6	75,1	77,2

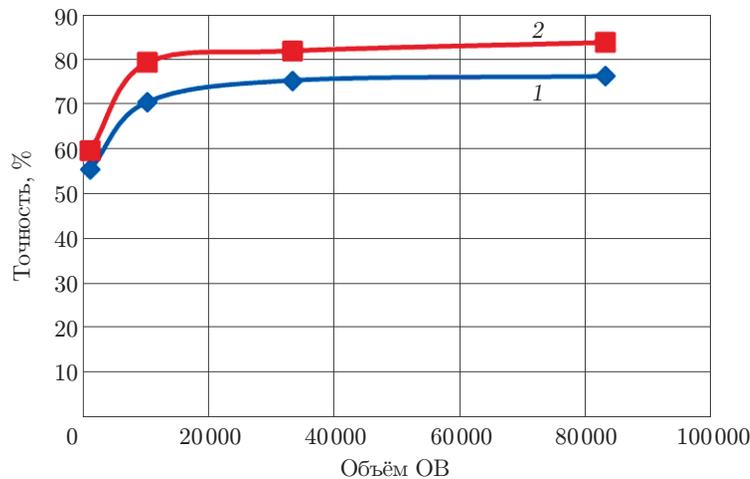


Рис. 6. Зависимость результирующей точности классификации от объема ОБ (кривая 1 — спектральная, 2 — спектрально-пространственная обработка)

сельной классификации (при любых способах формирования ОБ), приводят к увеличению точности не более чем на 2 %.

Следует отметить, что при обучении по фрагменту эффективность классификации крупноформатного изображения невысока (64,1 %), а методы, основанные на учёте пространственных признаков, не позволяют добиться её существенного повышения. В частности, анализ по прямоугольному окну приводит к увеличению результирующей точности в пределах 3 %, а анализ внутри сегментов — даже к незначительному снижению. Однако при использовании выборки такого же объема, сформированной случайным образом из всего изображения, точность спектральной классификации повышается до 70,5 %, а дополнительная пространственная обработка позволяет достичь 79,4 %. Это объясняется тем, что пиксели одного и того же класса (по наземным данным) разных пространственных зон снимка действительно имеют несколько отличающиеся параметры и выбранные для обучения области фрагмента плохо характеризуют соответствующие классы на всём изображении. Каждый пиксель ОБ в большей степени характеризует лишь некоторое количество пространственно близких к нему пикселей, а таких существенно меньше, чем при формировании ОБ случайным образом по всему изображению. При этом очевидно, что более практичным является построение обучающих выборок из связанных областей.

На рис. 6 показана зависимость точности спектральной и спектрально-пространственной классификаций (с применением метода SVM) от объема обучающей выборки при её формировании путём случайного выбора пикселей по всему изображению. При увеличении количества пикселей в ОБ приблизительно от 0,3 до 3,0 % точность классификации растёт с 60 до 80 %, однако дальнейшее расширение ОБ не приводит к значительным изменениям. Вклад в увеличение точности классификации пространственных признаков максимален при объеме ОБ ~ 10000 пикселей (3,0 %).

Заключение. Исследованы методы спектральной и спектрально-пространственной классификаций гиперспектральных данных. Экспериментально показано, что спектральная классификация крупноформатного ГС-изображения на 8–10 % эффективнее классификации аналогичного мультиспектрального. Целесообразно использовать (при правильном выборе) не более 20 признаков, поскольку увеличение их количества практически не влияет на результирующую точность.

Установлено, что эффективность обработки гиперспектральных данных существенно зависит от способа формирования обучающей выборки. Так, точность спектральной классификации крупноформатного изображения при применении в качестве ОБ всех пикселей

выделенного фрагмента составила 64,1 %, а дополнительная пространственная обработка позволила увеличить её не более чем на 3 %. В случае обучения по выборке такого же объёма, сформированной случайным образом из всего изображения, точность спектральной классификации повысилась до 70,5 %, а спектрально-пространственной — до 79,4 %.

Продемонстрировано существенное различие результатов при обработке крупноформатного изображения и его фрагмента. При близкой точности их спектральной классификации (76,3 и 79,9 % соответственно) дополнительная пространственная обработка в первом случае позволила повысить её до 84,0 %, а во втором — до 93,3 %, т. е. примерно на 7 и 14 %. Это необходимо учитывать при исследовании эффективности методов классификации, основанных на совместном анализе спектральных и пространственных признаков.

На примере крупноформатного изображения и его фрагмента показано, что методы, базирующиеся на предварительном уточнении значений пикселей за счёт пространственной обработки (до спектральной классификации), обеспечивают большую точность, чем методы, основанные на постобработке картосхем попиксельной спектральной классификации путём выбора доминирующего класса в локальных зонах (прямоугольных окнах или сегментах).

Для дальнейшего повышения эффективности обработки гиперспектральных изображений представляется перспективным развитие рассмотренных подходов в части применения различных способов сегментации и процедур адаптивного 3D-сглаживания (по спектральной и двум пространственным координатам) на этапе предварительной обработки.

СПИСОК ЛИТЕРАТУРЫ

1. **Козодеров В. В., Кондранин Т. В., Дмитриев Е. В.** Распознавание природно-техногенных объектов по гиперспектральным самолётным изображениям // *Исследование Земли из космоса*. 2014. № 1. С. 35–42.
2. **Plaza A., Du Q., Bioucas-Dias J. M. et al.** Foreword to the special issue on spectral unmixing of remotely sensed data // *IEEE Trans. Geosci. and Remote Sensing*. 2011. **49**, Is. 11. P. 4103–4110.
3. **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.
4. **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.
5. **Huang X., Zhang L.** An SVM ensemble approach combining spectral, structural, and semantic features for the classification of high-resolution remotely sensed imagery // *IEEE Trans. Geosci. and Remote Sensing*. 2013. **51**, Is. 1. P. 257–272.
6. **Wang Z., Nasrabadi N. M., Huang T. S.** Spatial-spectral classification of hyperspectral images using discriminative dictionary designed by learning vector quantization // *IEEE Trans. Geosci. and Remote Sensing*. 2014. **52**, Is. 8. P. 4808–4822.
7. **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.
8. **Li W., Ran Q., Du Q., Yang C.** Improved classification of conservation tillage practices using hyperspectral imagery with spatial-spectral features // *Proc. of the 3rd Intern. Conf. on Agro-geoinformatics*. Beijing, China, 2014. DOI: 10.1109/Agro-Geoinformatics.2014.6910589.

9. **Li W., Hu W., Ran Q. et al.** Improving hyperspectral image classification using smoothing filter via sparse gradient minimization // Proc. of the 8th IAPR Workshop on Pattern Recognition in Remote Sensing. Stockholm, Sweden, 2014. DOI: 10.1109/PRRS.2014.6914279.
10. **Palsson F., Ulfarsson M., Sveinsson J. R.** Hyperspectral image denoising using a sparse low rank model and dual-tree complex wavelet transform // Proc. of the IEEE Intern. Conf. on Geoscience and Remote Sensing. Quebec, Canada, 2014. P. 3670–3673. DOI: 10.1109/IGARSS.2014.6947279.
11. **Borhani M., Ghassemian H.** Hyperspectral image classification based on spectral-spatial features using probabilistic SVM and locally weighted Markov Random Fields // Proc. of the Iranian Conf. on Intelligent Systems. Bam, Iran, 2014. DOI: 10.1109/IranianCIS.2014.6802573.
12. **Borhani M., Ghassemian H.** Hyperspectral image classification based on non-uniform spatial-spectral kernels // Proc. of the Iranian Conf. on Intelligent Systems. Bam, Iran, 2014. DOI: 10.1109/IranianCIS.2014.6802579.
13. **Ye Z., He M., Fowler J. E., Du Q.** Hyperspectral image classification based on spectra derivative features and locality preserving analysis // Proc. of the IEEE China Summit & Intern. Conf. on Signal and Information Processing. Xian, China, 2014. P. 138–142. DOI: 10.1109/ChinaSIP.2014.6889218.
14. **Бондур В. Г.** Современные подходы к обработке больших потоков гиперспектральной и многоспектральной аэрокосмической информации // Исследование Земли из космоса. 2014. № 1. С. 4–16.
15. **Пестунов И. А., Рылов С. А.** Алгоритмы спектрально-текстурной сегментации спутниковых изображений высокого пространственного разрешения // Вестн. КемГУ. 2012. 2, № 4(52). С. 104–109.
16. **Кузнецов А. В., Мясников В. В.** Сравнение алгоритмов управляемой поэлементной классификации гиперспектральных изображений // Компьютерная оптика. 2014. 38, № 3. С. 494–502.
17. **Фурсов В. А., Бибииков С. А., Байда О. А.** Тематическая классификация гиперспектральных изображений по показателю сопряжённости // Компьютерная оптика. 2014. 38, № 1. С. 154–158.
18. **Fauvel M., Tarabalka Yu., Atli J. et al.** Advances in spectral-spatial classification of hyperspectral images // Proc. IEEE. 2013. 101, Is. 3. P. 652–675.
19. **Перспективные информационные технологии дистанционного зондирования Земли** / Под ред. В. А. Сойфера. Самара: Новая техника, 2015. 256 с.
20. **Борзов С. М., Потатуркин О. И.** Классификация типов растительного покрова по гиперспектральным данным дистанционного зондирования Земли // Вестн. НГУ. Сер. Информационные технологии. 2014. 12, вып. 4. С. 13–22.
21. **Борзов С. М., Потатуркин А. О., Потатуркин О. И., Федотов А. М.** Исследование эффективности классификации гиперспектральных спутниковых изображений природных и антропогенных территорий // Автометрия. 2016. 52, № 1. С. 3–14.
22. **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, Is. 1. P. 65–74.
23. **Lillesand T. M., Kiefer R. W., Chipman J. W.** Remote Sensing and Image Interpretation. N. Y.: John Wiley & Sons, 2004. 763 p.