

Оценка точности распознавания почвенно-растительных объектов по данным гиперспектрального зондирования и сканера ИСЗ QuickBird

Б.М. Балтер¹, Д.В. Воронцов², В.В. Егоров¹, А.А. Ильин², А.П. Калинин³,
А.Г. Орлов², И.Д. Родионов⁴, И.П. Родионова⁴

¹ *Институт космических исследований РАН
117997, Москва, ул. Профсоюзная, 84/32
E-mail: victor_egorov@mail.ru*

² *ЗАО Научно-технический центр "Реагент"
119991, Москва, ул. Косыгина, 4
E-mail: ilyinandrey@mail.ru*

³ *Институт проблем механики РАН
119526, Москва, просп. Вернадского, 101, к. 1
E-mail: kalinin@ipmnet.ru*

⁴ *Институт химической физики им. Н.Н. Семенова РАН
119991, Москва, ул. Косыгина, 4
E-mail: irodionov@reagent-rdc.ru*

Рассматриваются задачи обработки гиперспектральных данных и оценки точности распознавания почвенно-растительных объектов по данным гиперспектрального зондирования с борта авианосителя и сканера ИСЗ QuickBird. В качестве метода классификации с обучением был выбран метод максимума правдоподобия (МП) с возможностью установки порога отказа от классификации и весов объектов. Метод МП позволяет планировать показатели точности путем выбора соответствующих весов объектов и порога отказа от классификации. Показано, что метод МП дает на обучающих участках по большинству показателей стабильно более высокую точность для гиперспектрометра, чем для сканера. При переходе от обучающих участков к большой территории сканер теряет точность заметно быстрее, чем гиперспектрометр. Данные гиперспектрометра более устойчивы, чем данные сканера, к ошибкам в определении обучающих участков.

Введение

При дистанционном зондировании (ДЗ) Земли с аэрокосмических платформ наряду с многоспектральными сканерами (QuickBird Satellite Images. <http://www.satimagingcorp.com/gallery-quickbird.html>) все более широкое применение находят бортовые гиперспектрометры [1-3]. Данные этих сенсоров используются для классификации и оценки состояния объектов зондирования [4], что является предметом тематической обработки получаемой информации. Однако методы тематической обработки гиперспектральных данных и оценки точности распознавания типов зондируемых объектов развиты недостаточно. Также не уделяется достаточно внимания вопросам сравнения результатов классификации объектов зондирования по данным гиперспектральной и многоспектральной съемки. Проблемы совместной обработки наземных, авиационных и космических данных представляются весьма важными с методической точки зрения для отработки процедур распознавания, классификации и оценки состояния зондируемых объектов земной поверхности. В частности, это касается задач классификации типов растительности на основе данных гиперспектрального и многоспектрального зондирования и оценки точности распознавания почвенно-растительных объектов. Результаты этой работы будут полезны при обработке данных спутниковой гиперспектральной съемки.

В связи с этим в работе исследовались методы обработки экспериментальных данных, полученных с помощью авиационного гиперспектрометра, разработанного в НТЦ «Реагент» [5], камерой видео сопровождения и многоспектральным сенсором ИСЗ Quickbird.

Целью статьи является изложение методов классификации почвенно-растительных объектов по данным авиационного гиперспектрального зондирования и сенсора ИСЗ Quickbird, а также сравнительная количественная оценка достоверности распознавания и классификации этих объектов.

Методика съемки и полученные материалы

Гиперспектрометр устанавливался на вертолет Ми-8МТВ. Основные характеристики гиперспектрометра: спектральный диапазон – 500 – 900 нм; спектральное разрешение -1 – 10 нм; пространственное разрешение – $1 \cdot 10^{-3}$ рад; число спектральных каналов – 224; отношение сигнал/шум – более 100.

В табл. 1 приведены данные соответствия спектральных диапазонов многоспектрального сенсора ИСЗ QuickBird и каналов гиперспектрометра. В нижней строке таблицы указаны каналы гиперспектрометра, условно выбранные как центры диапазонов многоспектрального сенсора.

Таблица 1. Соответствие диапазонов многоспектрального сенсора ИСЗ QuickBird и каналов гиперспектрометра

Сенсор	Диапазон, нм			
QuickBird	450-530	520-610	640-720	770-880
Гиперспектрометр	500-530 (каналы 1-7)	520-610 (каналы 4-45)	640-720 (каналы 54-98)	770-860 (каналы 146-224)

Данные многоспектрального сенсора ИСЗ QuickBird имели пространственное разрешение 2 м. Разрешение гиперспектрометра поперек трассы составляло 0.15-0.2 м, а вдоль трассы – примерно 4 м.

На территории Пензенской области, на которой проводились дистанционные и наземные наблюдения, располагался тестовый полигон с 36 участками (размер участка $10 \times 10 \text{ м}^2$), занятыми различными типами растительности.

Исследуемые почвенно-растительные объекты были сгруппированы в три категории:

- целевой растительный объект;
- фоновые растительные объекты, объединенные в один объект - фон;
- участки без растительности (почва).

Кроме того, в ряде случаев использовался вспомогательный объект «остальное», обычно эквивалентный отказу от распознавания.

Трассовая съемка местности производилась в безоблачную погоду в июле 2006 г. с высоты 1000 м при скорости полета 130 км/ч. Синхронно с гиперспектральной осуществлялась видеосъемка с целью последующего проведения геометрической коррекции и привязки гиперспектральных данных [1]. На исследуемую территорию имелся многоспектральный снимок с ИСЗ Quickbird (рис. 1), полученный летом 2006 г. На нем линией, помеченной стрелкой, показана



Рис. 1. Снимок со спутника Quick Bird (в центре кадра белой рамкой выделен тестовый полигон). Линией со стрелкой показана трасса полета вертолета

трасса полета самолета, а белой рамкой выделен исследуемый участок.

Гиперспектральная съемка сопровождалась GPS-привязкой. Анализ полученных гиперспектральных данных осуществлялся в два этапа: предварительная (геометрическая коррекция и географическая привязка [1]) и тематическая обработка (классификация типов растительности). На рис. 2 приведено гиперспектральное изображение тестового полигона после предварительной обработки.

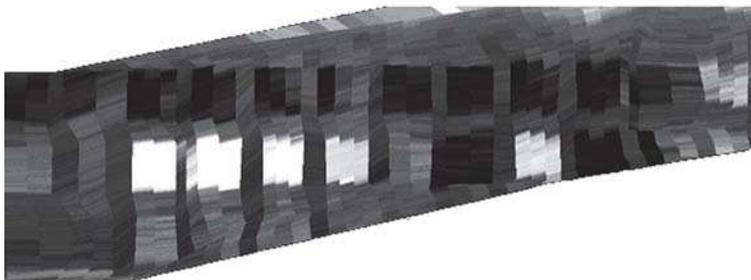


Рис. 2. Гиперспектральное изображение тестового полигона после предварительной обработки

Помимо гиперспектральных данных и материалов видеосъемки тестового полигона имелась наземная информация о типах растительности каждого участка полигона [3].

Тематическая обработка

Она включала три процедуры:

- выбор обучающих участков;
- кластеризацию;
- контролируемую классификацию растительных объектов с выделением двух классов – целевого и фоновый (классификацию с обучением).

Выбор обучающих участков

Нами применялись два типа обучающих участков: отдельные, выделенные вручную на гиперспектральном изображении и на многоспектральном изображении (рис. 3а) и их пересечения (рис. 3в). Полученные пересечения рассматриваются как «ядра» данных гиперспектрометра и многоспектрального сенсора. Как правило, эти «ядра» использовались в качестве обучающих данных, а охватывающие их обучающие участки, специфичные для гиперспектрометра и многоспектрального сенсора, – как «расширенные» тестовые участки. При изучении влияния изменения пространственного разрешения сенсоров потребовались также участки со «сплошным» покрытием, т.е. расположенные на фоне «почвы» (рис. 4).

Кластеризация по Кохонену

Существует несколько различных алгоритмов кластеризации. Одним из эффективных способов кластеризации точек в пространстве большой размерности является метод Кохонена на основе нейросети [6]. Его также называют методом самообучающихся карт (Self Organizing Maps - SOM). Процедура классификации без обучения начинается с построения отображения Кохонена из многомерного пространства спектральных данных (точек, являющихся концами векторов многомерных спектральных измерений) на двумерную поверхность с последующей кластеризацией данных на этой поверхности методом ISODATA.

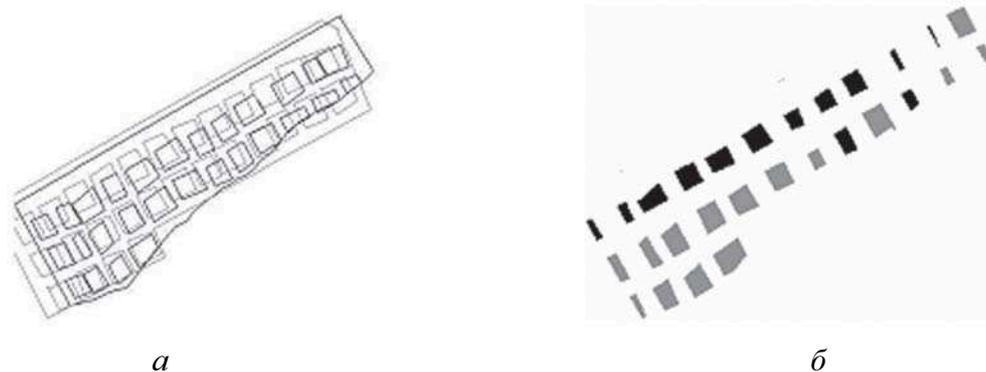


Рис. 3. Формирование обучающих участков: а – контуры тестовых участков, полученных по данным гиперспектральной съемки (выделены серым цветом) и многоспектральной съемки (темный цвет); б – пересечения изображений участков для гиперспектрометра и многоспектрального сенсора («ядра»)

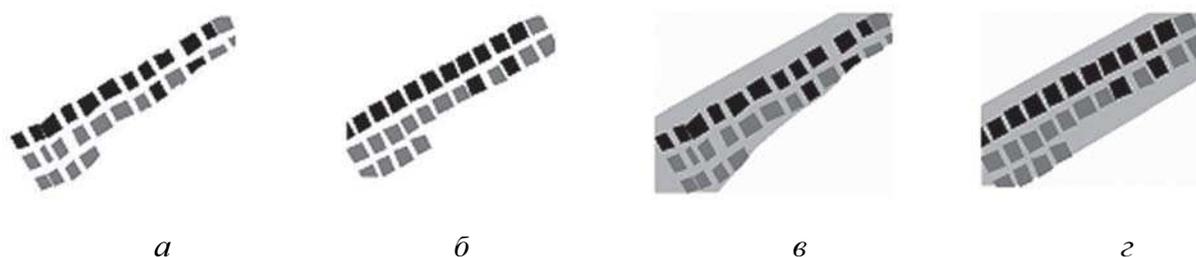


Рис. 4. Варианты тестовых участков: а и б – расширенные тестовые участки, полученные по данным гиперспектральной и многоспектральной съемки, соответственно; в и г – сплошные тестовые участки, полученные по данным гиперспектральной и многоспектральной съемки, соответственно. Черный цвет – целевой объект, темно-серый – растительный фон, бледно-серый – почва

Кластеризация объектов тестового полигона

После построения отображения Кохонена через него пропускаются все точки данных, и для каждой точки спектральных измерений получается свой класс, в зависимости от того, в какой кластер SOM эта точка попадает. Результаты такой кластеризации для тестового полигона показаны на рис. 5.

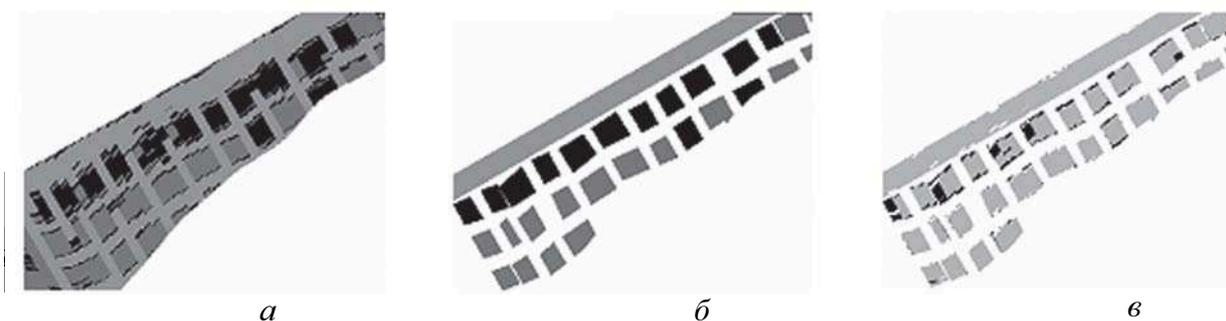


Рис. 5. Результаты кластеризации на основе метода Кохонена и сравнение с обучающими данными: а – результаты кластеризации; б – обучающие участки, выделенные вручную; в – их разница (белый цвет – нет данных, серый – классы совпадают, черный – классы различаются)

Из анализа рисунка следует, что кластеризация дает более сложные формы изображений участков, чем ручное выделение. Вопрос в том, насколько эти детали формы истинны. Поскольку участки тестового полигона делались квадратными, можно было бы считать все извилистые формы ошибками, если бы не возможность того, что они связаны с реальными сложностями геометрии съемки.

На основании результатов, показанных на рис. 5, была рассчитана матрица точности кластеризации. Она характеризуется двумя величинами – вероятностью ложной тревоги FA для каждой пары «истинный объект – кажущийся (альтернативный) объект» и вероятностью правильного обнаружения PD, которые представлены в табл. 2.

Таблица 2. Матрица точности кластеризации по отношению к обучающим участкам, выделенным вручную. По диагонали (серым цветом) – вероятность совпадения класса (PD), вне диагонали – вероятность ложной тревоги (FA), т.е. вероятность принять за класс, соответствующий столбцу, класс, соответствующий строке

Объекты классификации, выделенные вручную	Объекты, выделенные по результатам кластеризации (SOM)		
	Почва	Растительность	Цель
Почва	1	0.0018	0
Растительность	0.021	0.98	0.0029
Цель	0.027	0.18	0.79

Из табл. 2 видно, что почва и фоновая растительность классифицируются с высокой вероятностью правильного обнаружения. Целевой объект классифицируется несколько хуже (PD=0,79), поскольку он сопровождается высокими значениями ложной тревоги, связанной с отнесением его к фоновому объекту (FA=0,18). Вероятность принятия почвы за целевой объект невелика (FA=0,027), в силу большого различия их спектральных сигнатур.

Кластеризация всей трассы гиперспектральной съемки

Она была выполнена в нескольких вариантах, различающихся исходными условиями для построения карты Кохонена. На рис. 6 показаны результаты кластеризации всей трассы полета методом Кохонена. На нем представлены три варианта кластеризации, соответствующие разным

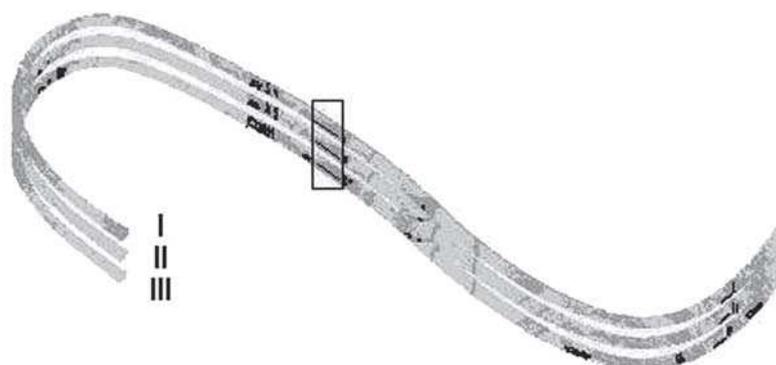


Рис. 6. Результаты кластеризации всей трассы методом Кохонена: I – для случая формирования центров кластеров по «ядрам»; II – для случайной выборки 1% из точек тестового полигона; III – для случайной выборки 1% из точек всей трассы. Рамкой выделен тестовый полигон на трассе

условиям формирования центров кластеров. Черным цветом выделены участки трассы, соответствующие цели. Цифрой I обозначен результат кластеризации трассы для случая формирования центров кластеров по «ядрам». Видно, что в этом случае вероятность ложной тревоги минимальна. Цифрой II показан результат, относящийся к случаю формирования центров кластеров для случайной выборки 1% из точек тестового полигона. В этом случае вероятность ложной тревоги несколько выше. Цифрой III обозначен результат для случайной выборки 1% из точек всей трассы. Очевидно, что для этого варианта вероятность ложной тревоги больше, что возможно вызвано с появлением на трассе участков, соответствующих обочинам дорог, теням от облаков, а также с вероятным изменением условий формирования гиперспектральных образов зондируемых объектов. Отсюда следует, что наилучшим ва-

риантом кластеризации в смысле минимизации вероятности ложной тревоги представляется случай с построением карты Кохонена на основе «ядер».

Классификация методом максимального правдоподобия (МП)

В качестве метода классификации с обучением будем рассматривать только метод максимума правдоподобия (МП) с возможностью установки весов и порога отказа от классификации при малых уровнях значений сигнатур классифицируемых объектов. Выбор этого метода обусловлен тем, что он, согласно работе [1], обеспечивал максимальную вероятность правильной классификации при распознавании растительных объектов того же самого региона. Результаты классификации описываются тремя основными способами:

- изображениями, картирующими полученные классы;
- матрицей точности классификации;
- кривыми ошибок пропуска цели (1-PD) и ложной тревоги (в зависимости от изменения веса одного из объектов или в зависимости друг от друга).

В матрицах точности классификации (табл. 2 и 3) по диагонали жирным шрифтом выделены значения вероятностей правильного обнаружения объекта, вне диагонали – вероятность ложной тревоги объекта.

Один из важнейших предметов исследования в данном разделе является установление зависимости точностных показателей метода МП от выбора обучающих участков, на которых строятся спектральные сигнатуры объектов, и тестовых участков, на которых оценивается точность по соответствию результатов классификации известной карте классов этих участков, которая предполагается абсолютно безошибочной. На точность классификации оказывает влияние придание весов трем объектам: цель, растительность, почва. Весом, придаваемым объекту, может служить отношение площади объекта ко всей исследуемой площади, либо, множитель, характеризующий степень важности классифицируемого объекта.

Можно выбирать веса объектов так, чтобы получить желаемый баланс ошибок для разных объектов. Как правило, за меру ошибки берется сумма ошибок 1 и 2 рода, т.е. соответственно, вероятность ложной тревоги и вероятность пропуска цели. Даже небольшие изменения соотношений весов цели, фоновой растительности и почвы приводят к тому, что ошибка классификации одного из этих объектов уменьшается за счет увеличения ошибок другого.

В табл. 3 приведены матрицы точности классификации без оптимизации весов, а в табл. 3 – с оптимизацией по критерию минимума суммы ошибок 1 и 2 рода для трех объектов. Темно-серым выделены ошибки более 0.2, светло-серым – более 0.1 (напомним, что по диагонали – вероятности правильного распознавания).

Таблица 3. Матрица точности классификации. Обучение на участках, соответствующих «ядрам кластеризации». Равные веса объектов

Тест	Истинный класс	Сканер Результат распознавания			Гиперспектрометр Результат распознавания		
		Почва	Растительность	Цель	Почва	Растительность	Цель
На «ядрах»	Почва	0.92	0.042	0.0009	1	0.0013	0
	Растительность	0.15	0.73	0.016	0.00046	1	0
	Цель	0.0051	0.019	0.95	0.00015	0.0042	0.99
На «расширенных» участках	Почва	0.92	0.034	0	0.82	0.087	0.0052
	Растительность	0.15	0.65	0.038	0.0004	1	0
	Цель	0.023	0.15	0.7	0.00024	0.073	0.85

На основании полученных матриц точности классификации можно констатировать:

- классификация, выполненная по данным гиперспектрометра, характеризуется более высокой точностью, чем аналогичная процедура по данным сканера;
- оптимизация весов объектов заметно сказывается на результатах классификации по данным гиперспектрометра и значительно менее – для данных сканера;
- выбор тестовых участков важен для сканера и менее важен – для гиперспектрометра.

Таблица 4. Матрица точностей классификации. Обучение на участках, соответствующих «ядрам кластеризации». Оптимизированные веса

Тест	Истинный класс	Сканер Результат распознавания			Гиперспектрометр Результат распознавания		
		Почва	Растительность	Цель	Почва	Растительность	Цель
На «ядрах»	Почва	0.93	0.04	0	0.98	0.0002	0.01
	Растительность	0.14	0.67	0.041	0.0055	0.87	0.061
	Цель	0.019	0.14	0.72	0.0045	0.0034	0.98
На «расширенных» участках	Почва	0.92	0.022	0.038	0.93	0.038	0.019
	Растительность	0.32	0.32	0.019	0.031	0.94	0
	Цель	0.048	0.037	0.74	0.039	0.012	0.87

На рис. 7 изображены карты классов как результат МП-классификации в зависимости от выбора обучающих участков и весов объектов. Видно, что оптимизация по «расширенным» участкам дает визуально заметные ошибки классификации почвы, лежащей вне тестовых участков, и потому не сказывающиеся на оценках точности цели.

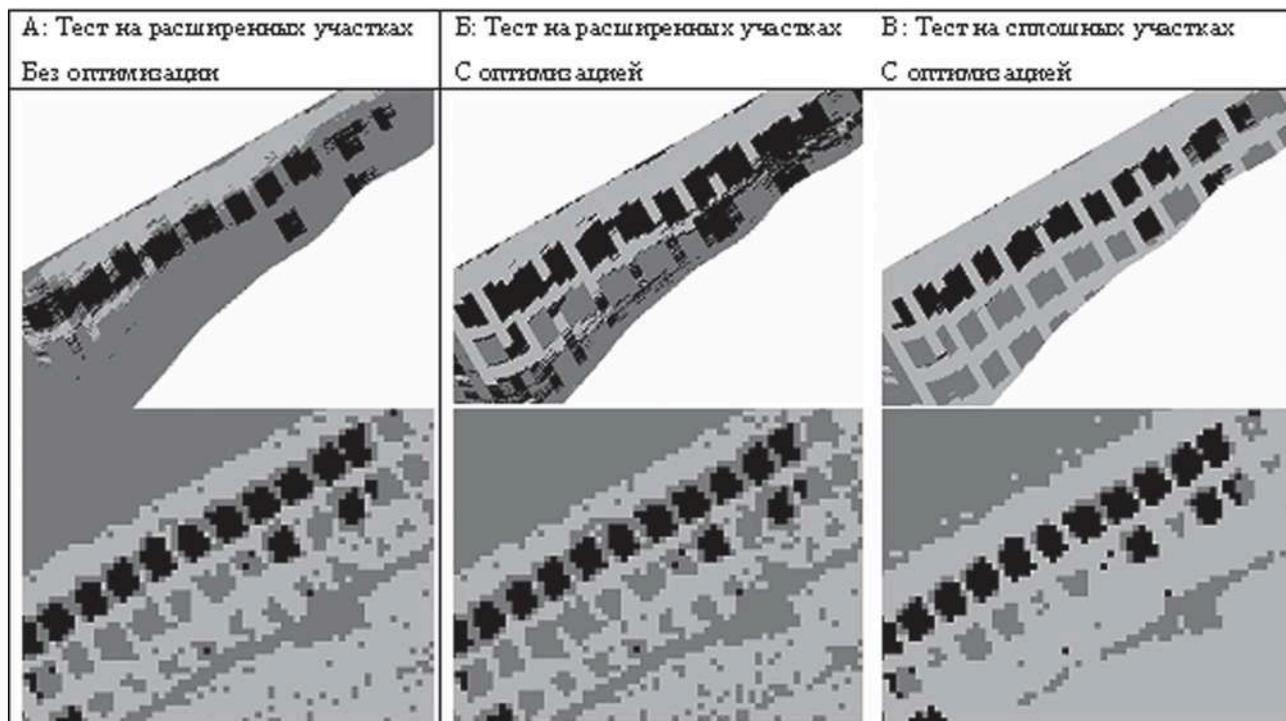


Рис. 7. Результаты МП-классификации данных гиперспектрометра (а) и сканера (б). Обучение на «ядрах», тест – на различных участках с равными или оптимизированными весами объектов

Рассмотрим случай выбора тестовых участков – внутри обучающих. Это сделано для сравнения двух вариантов обучающих участков – «своих» и «чужих» («свои» означает выбор как тесто-

вых, так и обучающих участков по данным одного и того же сенсора, а «чужие» - когда выбор тестовых и обучающих участков сделан по данным разных сенсоров). Выбор обучающих и тестовых участков на основании рис. 4а – «свой» для гиперспектрометра и «чужой» для сенсора ИСЗ QuickBird, а вариант на основе рис. 4б – наоборот. Общее для них подмножество («ядра») – выбрано в качестве тестового для сравнения обоих вариантов «свой» - «чужой». Понятно, что «правильный» вариант должен быть лучше; вопрос в том, насколько, и как это преимущество зависит от параметров алгоритма распознавания. Такой подход дает оценку степени критичности правильного оконтуривания обучающего участка.

Табл. 5 и 6 представляют результаты точности классификации по данным гиперспектрометра и сканера (без оптимизации весов).

Таблица 5. Матрица точностей классификации по данным гиперспектрометра

Тестовые участки	Истинный класс	Обучение по «своему» варианту			Обучение по «чужому» варианту		
		Результат распознавания			Результат распознавания		
		Почва	Растительность	Цель	Почва	Растительность	Цель
«свои»	Почва	0.99	0.0043	0.00055	0.98	0.0037	0.0022
	Растительность	0.0018	1	0.00016	0.0088	0.87	0.079
	Цель	0.0023	0.0052	0.98	0.049	0.018	0.87
«ядра»	Почва	1	0.00019	0	0.97	0.00076	0.014
	Растительность	0.0025	1	0.00015	0.00015	0.99	0.0056
	Цель	0.0023	0.0034	0.99	0	0.0036	0.99

Таблица 6. Матрица точностей классификации по данным сканера

Тестовые участки	Истинный класс	Обучение по «чужому» варианту			Обучение по «своему» варианту		
		Результат распознавания			Результат распознавания		
		Почва	Растительность	Цель	Почва	Растительность	Цель
«свои»	Почва	0.77	0.073	0.045	0.92	0.032	0.00035
	Растительность	0.24	0.42	0.051	0.1	0.69	0.068
	Цель	0.13	0.036	0.66	0.006	0.054	0.9
«ядра»	Почва	0.82	0.093	0.00088	0.82	0.086	0.0084
	Растительность	0.22	0.52	0.071	0.098	0.75	0.057
	Цель	0.012	0.0025	0.96	0.00015	0.026	0.94

Потеря точности за счет использования «неправильных» обучающих участков существеннее всего для фоновой растительности при работе по данным сканера. Можно сказать, что данные гиперспектрометра более устойчивы по отношению к процедуре выбора обучающих участков, чем данные сканера QuickBird.

Выводы

1. Все методы выбора обучающих участков чувствительны к попаданию в обучающий участок «не своих» объектов. Это больше всех других факторов снижает точность классификации. Для всех методов классификации существенные потери точности происходят при переходе от обучающих участков к участкам всей трассы.

2. Процедуру кластеризации по Кохонену, как средство классификации, нельзя рассматривать как самостоятельный метод. Ее можно использовать как метод скрининга – для предварительного анализа территории. Наилучшие перспективы у кластеризации – использование ее для выбора обучающих участков. При этом проявляется высокая устойчивость результатов кластеризации к выбору исходных данных.

3. Метод МП позволяет планировать показатели точности путем выбора соответствующих весов объектов. Однако эти показатели могут отклоняться от реальных точностей по мере ухода от обучающих участков.

4. Сравнение результатов классификации по данным гиперспектрометра и сканера ИСЗ QuickBird показывает, что:

- метод МП дает на обучающих участках по большинству показателей стабильно более высокую точность для данных гиперспектрометра, чем для сканера;
- при переходе от обучающих участков к рабочим участкам на большей территории сканер теряет точность заметно быстрее, чем гиперспектрометр;
- данные гиперспектрометра обеспечивают получение более устойчивых результатов классификации по отношению к выбору обучающих участков, чем данные сканера.

Работа выполнена при поддержке гранта РФФИ 06-08-01576.

Литература

1. Балтер Б.М., Егоров В.В., Ильин А.А. и др. Оценка возможностей гиперспектральной съемки для дистанционного обнаружения заданного типа растительности. Препринт ИКИ РАН Пр-2134. 2007. 30 с.
2. Непобедимый С.П., Родионов И.Д., Воронцов Д.В. и др. Гиперспектральное дистанционное зондирование Земли // Доклады Академии наук. 2004. Том 397. №1. С. 45-48.
3. Балтер Д.М., Белов А.А., Воронцов Д.В. и др. Проект спутникового гиперспектрометра, предназначенного для малого космического аппарата // Исслед. Земли из космоса. 2007. №2. С. 43-55.
4. Воронцов Д.В., Егоров В.В., Калинин А.П. и др. Принципы обработки гиперспектральной информации и результаты летных испытаний прототипа авиационного гиперспектрометра // Вестник МГТУ им. Н.Э. Баумана. Сер. «Приборостроение», 2006, №4. С.27-37.
5. Калинин А.П., Орлов А.Г., Родионов И.Д. Авиационный гиперспектрометр // Вестник МГТУ им. Н.Э.Баумана. Сер. «Приборостроение», 2006, №3. С.11-24.
6. Kohonen T. Self-organization and associative memory. Series in Information Sciences. V. 8. Berlin: Springer verlag, 1984.