

Глубокая обработка данных вертолетного гиперспектрометра

Б.М. Балтер, Д.Б. Балтер, В.В. Егоров,¹
А.А. Белов, Д.В. Воронцов, А.А. Ильин, А.Г. Орлов²

¹ *Институт космических исследований РАН,
117997 Москва, Профсоюзная 84/32*

² *ЗАО НТЦ "Реагент"
125190 Москва, Балтийская 14
E-mail: Balter@iki.rssi.ru*

Описаны эксперименты по обработке данных вертолетной гиперспектрометрии с целью обнаружения растительных целей на растительном же фоне. Получены оценки ошибок пропуска цели и ложной тревоги в зависимости от метода обработки и параметров данных, в т.ч. спектрального и пространственного разрешения.

Введение

Использовались данные вертолетной гиперспектрометрии и космического многозонального сканера QuickBird. Гиперспектрометр имеет 224 спектральных канала в диапазоне 500-860 нм. Его данные были получены на площади в несколько квадратных километров с высоты 1 км и разрешением лучше 1 м. Центр этой площади – полигон «Мира» с более 20 видов растительности, характерных для средней полосы России. Объекты были сгруппированы в 3 категории: целевой растительный объект, фоновые растительные объекты, почва. Решались следующие задачи.

- Влияние выбора обучающих участков на обработку данных, в частности, эффект неточной геометрической привязки обучающих участков.
- Оценка качества классификации без учителя методом Кохонена (SOM) – как самостоятельного метода и как средства выбора обучающих участков.
- Оценка точности классификации методом максимума правдоподобия (МП) с возможностью ручной установки весов объектов. Точность выражалась через ошибки пропуска цели и ложной тревоги.
- Сравнение качества классификации по данным гиперспектрометра и сканера.
- Оценка влияния спектрального и пространственного разрешения на качество классификации по данным гиперспектрометра и сканера.

Авторы благодарят ФГУП "Госцентр "Природа" за данные об обучающих участках «Мира» и космические снимки QuickBird, предоставленные в рамках работ по ФЦП "Комплексные меры противодействия злоупотребления наркотиками и их незаконному обороту на 2005-2009 гг.", выполняемых НТЦ "Реагент", ФГУП "Госцентр "Природа" Роскартографии и ГНУ "ПензНИИСХ" РАСХН.

Геометрическая коррекция и привязка

Данные QuickBird имели пространственное разрешение 2 м. Данные гиперспектрометра имели разрешение поперек трассы 0.15-0.2 м, вдоль трассы – примерно 4 м. Такая геометрия создала серьезные проблемы с привязкой данных. Трасса гиперспектрометра не покрывает Миру полностью и проходит через нее наискось. Геометрическая привязка трассы осуществлялась на основе данных GPS, в предположении, что сканирование перпендикулярно трассе и прибор смотрит в надир. Кроме того, проводился расчет изменения ориентации вертолета по

последовательности видеок кадров, синхронизованных с гиперспектрометрией (Рис. 1). После определения геометрических искажений по видеоданным, над гиперспектральными данными проводится обратное преобразование, устраняющее искажения (Рис. 2). Тем не менее, ошибка геометрической привязки данных гиперспектрометра к данным QuickBird гораздо хуже, чем пиксел последних. Из-за этого не удалось создать единую систему обучающих участков для гиперспектрометра и QuickBird.

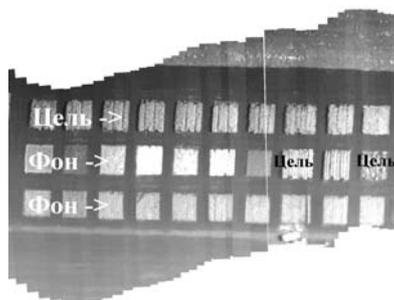


Рис. 1. Геометрические искажения трассы гиперспектрометра: привязка сопроводительных кадров видекамеры. Полигон «Мира»

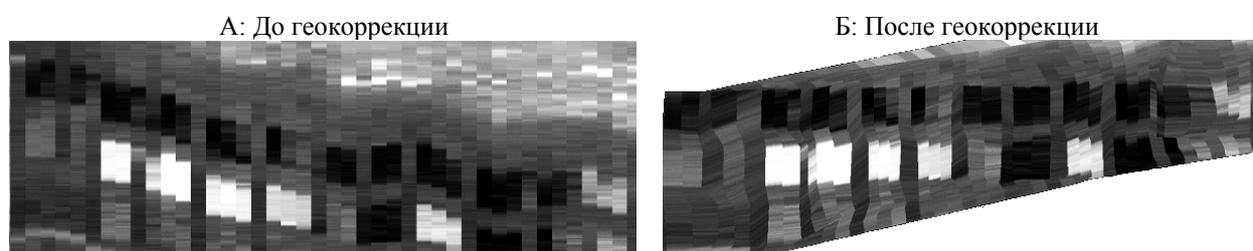


Рис. 2. Геокоррекция данных гиперспектрометра на Мире по сопроводительным кадрам видекамеры

Обучающие участки

Использовались 2 типа обучающих участков: отдельные, выделенные вручную для гиперспектрометра и QuickBird, и их пересечение (Рис. 3). Последнее рассматривается как «общий знаменатель» данных гиперспектрометра и QuickBird. Как правило, эти «ядра» использовались в качестве обучающих данных, а охватывающие их обучающие участки, специфичные для гиперспектрометра и QuickBird, - как расширенные тестовые участки. При изучении влияния ухудшенного пространственного разрешения потребовались также участки со «сплошным» покрытием (Рис. 4).

А: контура гиперспектрометра (черным) и сканера

Б: «Ядра» для цели (черным) и фона (серым)

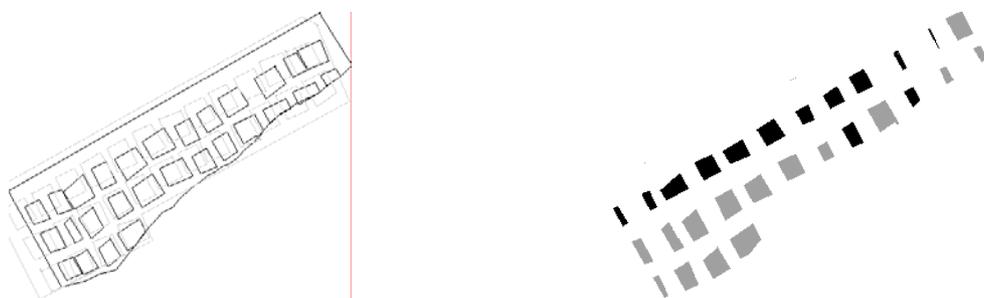


Рис. 3. «Ядра» обучающих участков – пересечения данных гиперспектрометра и сканера

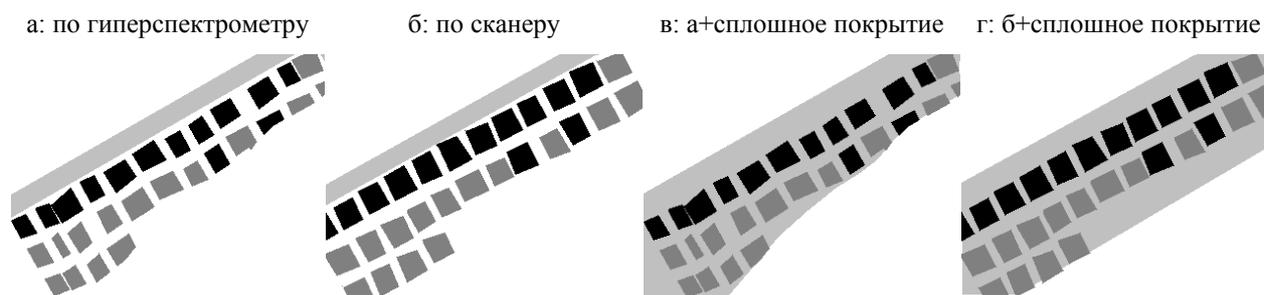


Рис. 4. Варианты расширенных (а, б) и сплошных (в, г) тестовых участков. Черное – цель, темно-серое – растительный фон, бледно-серое – почва. В картографической проекции

Проверялась сопоставимость данных гиперспектрометра и QuickBird в сопоставимых спектральных диапазонах (

Рис. 5). У гиперспектрометра бралось по одному спектральному каналу в середине диапазонов QuickBird. Разница во времени между съемкой - месяц: для гиперспектрометра 13 июля 2006 г., а для QuickBird – с 5 по 20 августа 2006 г. Сдвиг по фазе вегетации может привести к значительным изменениям спектральных портретов. Поэтому не приходится ожидать тесной корреляции.

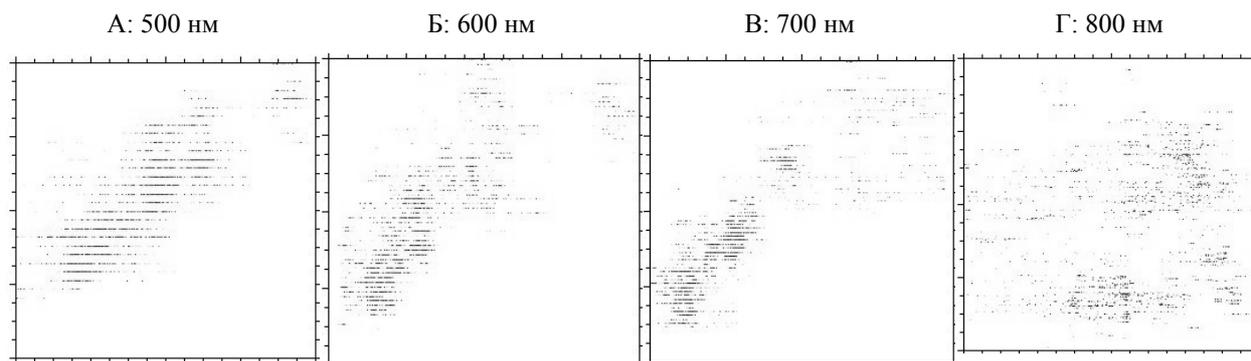


Рис. 5. Диаграмма рассеяния «гиперспектрометр (абсцисса) –сканер (ордината)» на соответственных длинах волн, по «ядрам» обучающих участков

Во всех каналах, кроме ИК, имеется примерно линейная зависимость умеренной тесноты между данными гиперспектрометра и QuickBird. В ИК-диапазоне зависимости практически нет, и причины этого пока неясны.

Рис. 6 - сравнение данных гиперспектрометра и QuickBird по гистограммам. В видимых диапазонах (но не в ИК) видно сходство данных гиперспектрометра и QuickBird как по форме, так и по взаимному расположению цели и растительности.

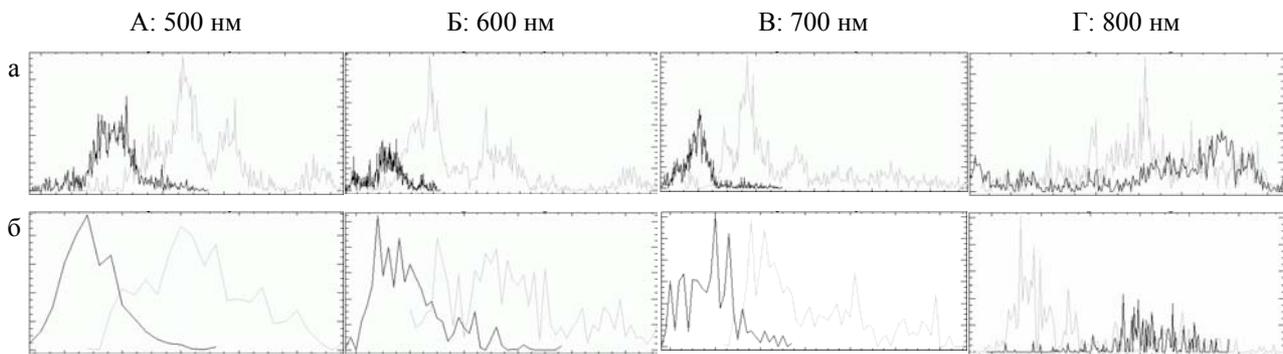


Рис. 6. Гистограммы яркости цели (жирным) и растительности (бледным) на обучающих участках – «ядрах». По данным гиперспектрометра (а) и сканера (б) на сопоставимых длинах волн

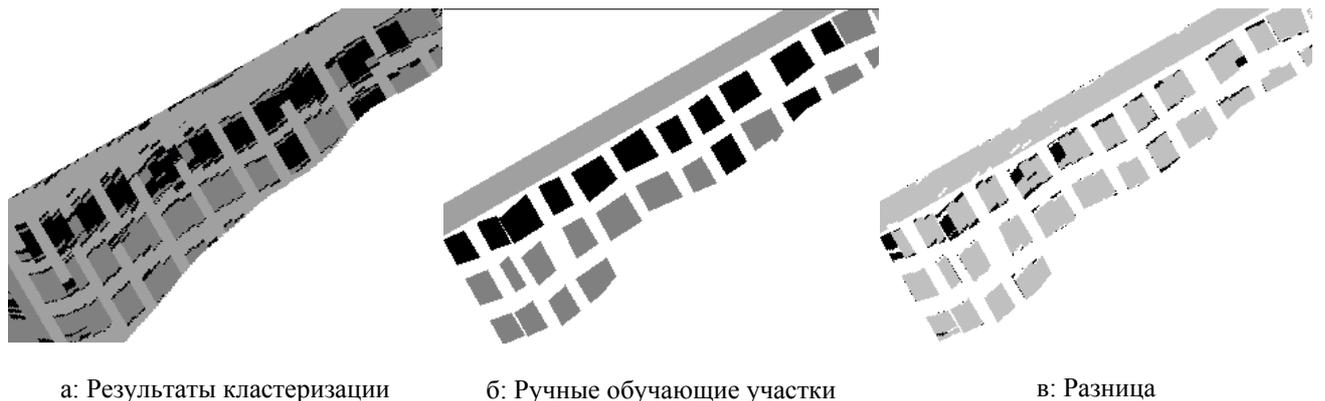
Вывод: данные гиперспектрометра и сканера нельзя обрабатывать совместно из-за проблем привязки, но можно обрабатывать отдельно и сравнивать результаты.

Кластеризация методом Кохонена

Классификация без обучения - построение отображения Кохонена (SOM) из многомерного пространства спектральных данных на двумерную поверхность и кластеризация данных на этой поверхности методом ISODATA. Исходные данные – либо случайно выбранные точки вдоль трассы, либо данные с обучающих участков (при классификации мы игнорируем информацию о том, какой объект на каком участке, но постфактум она используется для приписывания классов полученным кластерам). После построения SOM через него пропускаются *все* точки данных, и для каждой получается свой класс, в зависимости от того, в какой кластер SOM она попадает.

Рис. 7 показывает результаты. Кластеризация дает более сложные формы участков, чем ручное выделение. Вопрос в том, насколько эти детали формы истинны. Они могут быть артефактами или могут быть связаны с реальными сложностями геометрии съемки.

Представляет интерес сравнение спектральных сигнатур обучающих участков, полученных кластеризацией, с ручными обучающими участками (Рис. 8).

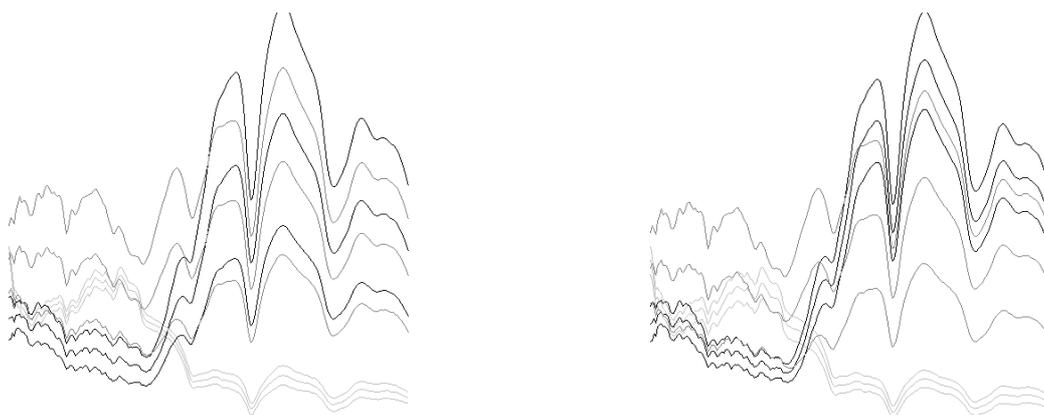


а: Результаты кластеризации

б: Ручные обучающие участки

в: Разница

Рис. 7. Обучающие участки, выделенные по данным гиперспектрометра вручную и по результатам кластеризации на основе данных с «ядер» (цветокод см. Рис. 4), а также их разница (белый цвет – нет данных, серый – классы совпадают, черный – классы различаются)



а: Спектры ручных обучающих участков

б: Спектры обучающих участков по SOM

Рис. 8. Сравнение спектров классов (средние \pm среднеквадратичное отклонение) для обучающих участков, выделенных вручную и по результатам кластеризации (цветокод см. Рис. 4)

Для обучающих участков, полученных кластеризацией, дисперсия спектра цели значительно меньше, чем для ручных (особенно в ИК-области). Это позволяет надеяться на более высокую точность классификации с обучением.

Классификация методом максимума правдоподобия

В качестве метода классификации с обучением использован метод максимума правдоподобия (МП) с возможностью установки порога отказа от классификации и весов объектов. Результаты классификации описываются картами классов, матрицей точности классификации и кривыми ошибок пропуска цели и ложной тревоги. В матрицах точности классификации по диагонали (жирным) – вероятность обнаружения объекта, вне диагонали – вероятность ложной тревоги объекта, соответствующего столбцу, за счет неправильного распознавания объекта, соответствующего строке. Нормировка вероятности ложной тревоги – на полное количество пикселей данных («на площадь»), либо на число пикселей объекта, соответствующего столбцу («на класс»). Точностные показатели оцениваются по соответствию карте классов тестовых участков. Исследуется зависимость показателей от выбора обучающих участков, на которых строятся спектральные сигнатуры объектов, и тестовых участков.

Строится зависимость результатов классификации от выбора весов каждого из трех объектов в виде «весового треугольника» (Рис. 9). Центр плоскости принимается за начало координат, соответствующее равным (единичным) весам 3 объектов. Из него выходят 3 оси под углом 120° друг к другу. Точка, лежащая между двумя осями, проектируется параллельно им, и полученные координаты дают два веса объектов, сопоставленных этим осям (R – цель, G – растительность, B – почва). Вес третьего объекта полагается равным единице. На этой основе можно выбирать веса объектов так, чтобы получить желаемый баланс ошибок разных объектов. Как правило, за меру ошибки мы берем сумму ошибок 1 и 2 рода. Тон представляет диапазон значений ошибок (по умолчанию – между 0 - черным и 1 - белым). Оптимальные комбинации весов соответствуют темным зонам. Даже небольшие изменения веса цели или растительности приводят к тому, что ошибка одного из этих объектов уменьшается за счет увеличения ошибки другого (Рис. 9. б). Выбор баланса весов зависит от выбора критерия, учитывающего качество классификации всех объектов.

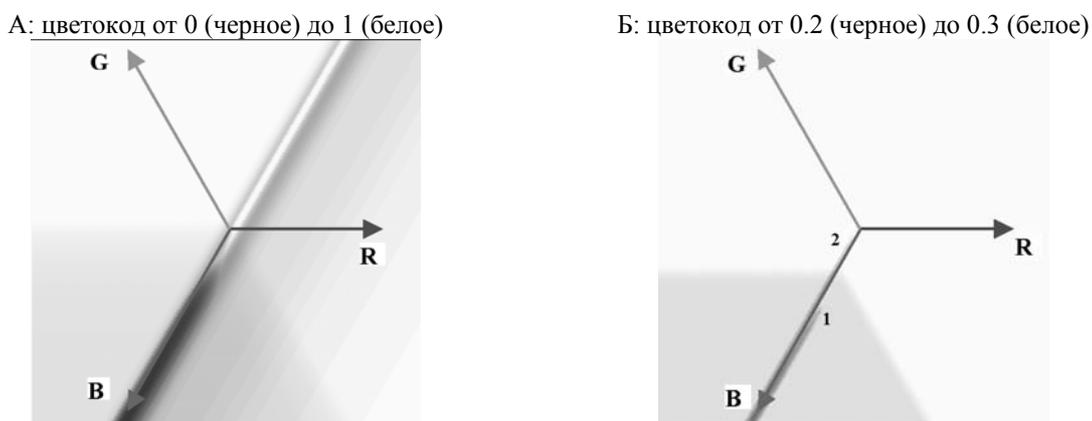


Рис. 9. «Треугольник весов» для гиперспектрометра. Цветом показана сумма ошибок 1 и 2 рода для 3 объектов. Справа: 1- область оптимума для объекта G, 2- для объекта R (соответственно, фон и цель). Обучение на «ядрах», тест на сплошных участках (в)

Для сканера весовой треугольник принципиально другой (Рисунок 10). Частично это может быть объяснено через резкое различие размерности спектра, но дело не только в этом: при сокращении числа каналов гиперспектрометра (см. ниже) различие сохраняется. Далее мы используем весовой треугольник и для сканера, и для спектрометра, как средство выбора весов, оптимальных по критерию суммы ошибок 1 и 2 рода 3 объектов.

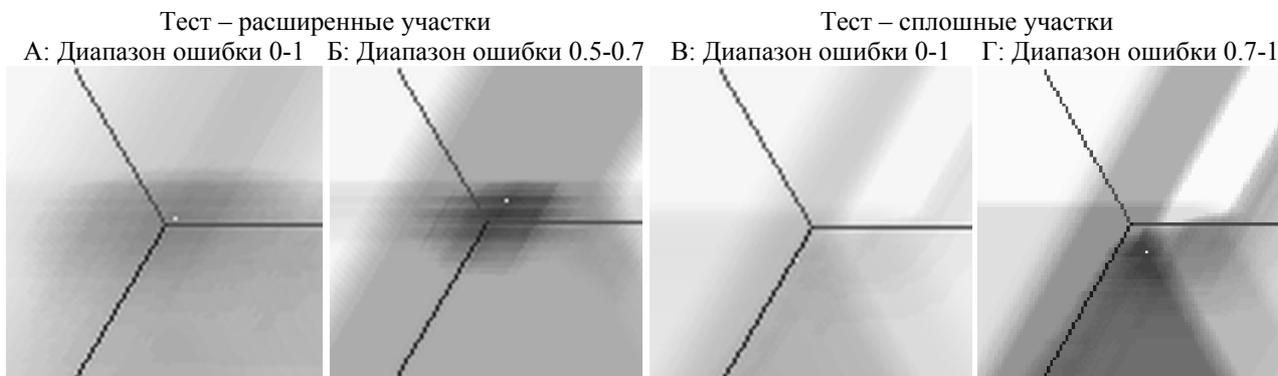


Рисунок 10 То же, данные сканера

Таблица 1 приводит матрицу точности классификации без оптимизации весов, а Таблица 2 – с оптимизацией. Темно-серым выделены ошибки более 0.2, светло-серым – более 0.1 (напомним, что по диагонали – вероятности *правильного* распознавания).

Таблица 1 Матрица точностей классификации. Обучение на ядрах. Равные веса объектов.

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

Таблица 2 Матрица точностей классификации. Обучение на ядрах. Оптимизированные веса.

	Истинный класс	Сканер			Гиперспектрометр		
		Результат распознавания			Результат распознавания		
		Почва	Растит.	Цель	Почва	Растит.	Цель
Тест на расшир. участках	Почва	0.9	0.04	0	0.98	0.0002	0.01
	Растит.	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
Тест на сплошных. участках	Почва	0.92	0.022	0.038	0.93	0.038	0.019
	Растит.	0.32	0.32	0.019	0.031	0.94	0
	Цель	0.048	0.037	0.74	0.039	0.012	0.87

1. Гиперспектрометр точнее сканера. Ниже показано, что дело не только в числе каналов.
2. Оптимизация заметно сказывается на гиперспектрометре и меньше – на сканере.
3. Выбор тестовых участков важен для сканера, меньше – для гиперспектрометра.

Рис. 11 приводит соответствующие карты классов. Видно, что оптимизация по расширенным участкам дает визуально заметные ошибки классификации почвы, но лежащие вне тестовых участков и потому не сказывающиеся на оценках точности.

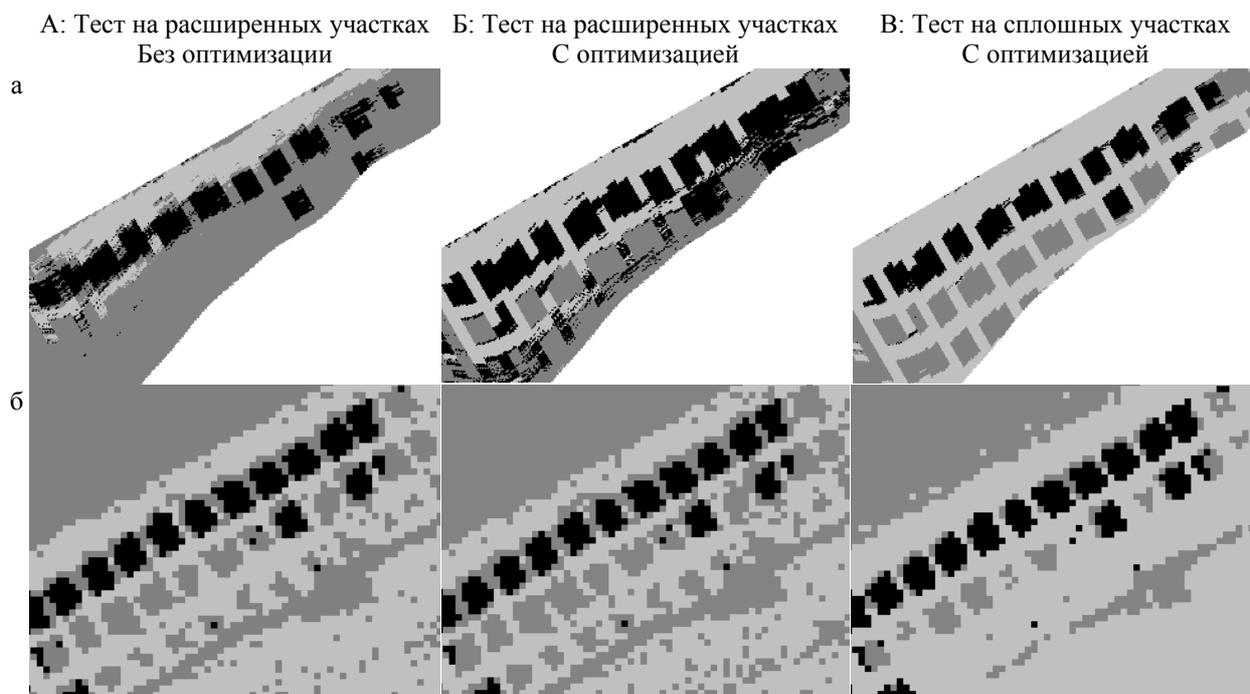


Рис. 11. Результаты МП-классификации данных гиперспектрометра (а) и сканера (б). Обучение на «ядрах», тест - на различных участках с равными или оптимизированными весами объектов

Далее тестовые участки выбираются нестандартно: внутри обучающих. Это сделано для сравнения двух вариантов выбора обучающих участков – «своих» и «чужих». Вариант а (Рис. 4) «свой» для гиперспектрометра и «чужой» для QuickBird, а вариант б – наоборот. Общее для них подмножество – «ядра» - выбрано в качестве тестового для сравнения обоих. Понятно, что «правильный» вариант должен быть лучше, вопрос в том, насколько, и как это преимущество зависит от параметров алгоритма. Это дает оценку степени критичности правильного оконтуривания обучающего участка.

Таблица 3 и Таблица 4 представляют результаты для гиперспектрометра и сканера (без оптимизации весов). Потеря точности за счет использования «неправильных» обучающих участков существеннее всего для растительности при работе по данным сканера. Можно сказать, что гиперспектрометр более устойчив, чем QuickBird, к ошибкам в выборе обучающего участка.

Таблица 3 Матрица точностей классификации по данным гиперспектрометра.

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

Таблица 4 Матрица точностей классификации по данным сканера.

	Истинный класс	Обучение по «чужому» варианту Результат распознавания			Обучение по «своему» варианту Результат распознавания		
		Почва	Растит.	Цель	Почва	Растит.	Цель
Тестовые участки =	Почва	0.77	0.073	0.045	0.92	0.032	0.00035
	Растит.	0.24	0.42	0.051	0.1	0.69	0.068

«СВОИ»	Цель	0.13	0.036	0.66	0.006	0.054	0.9
Тестовые участки – «ядра»	Почва	0.82	0.093	0.00088	0.82	0.086	0.0084
	Растит.	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

«Весовой треугольник» позволяет оптимизировать веса для совокупности 3 объектов. Кривые ошибок (Рис. 12) нацелены на оптимизацию точностного критерия, зависящего от вероятности распознавания PD и вероятности ложной тревоги FA для одного из объектов за счет подбора веса того же или другого объекта. Например, оптимальный способ снижения ошибок ложной тревоги для цели по данным гиперспектрометра – повышение веса почвы (как показывает и Рис. 9).

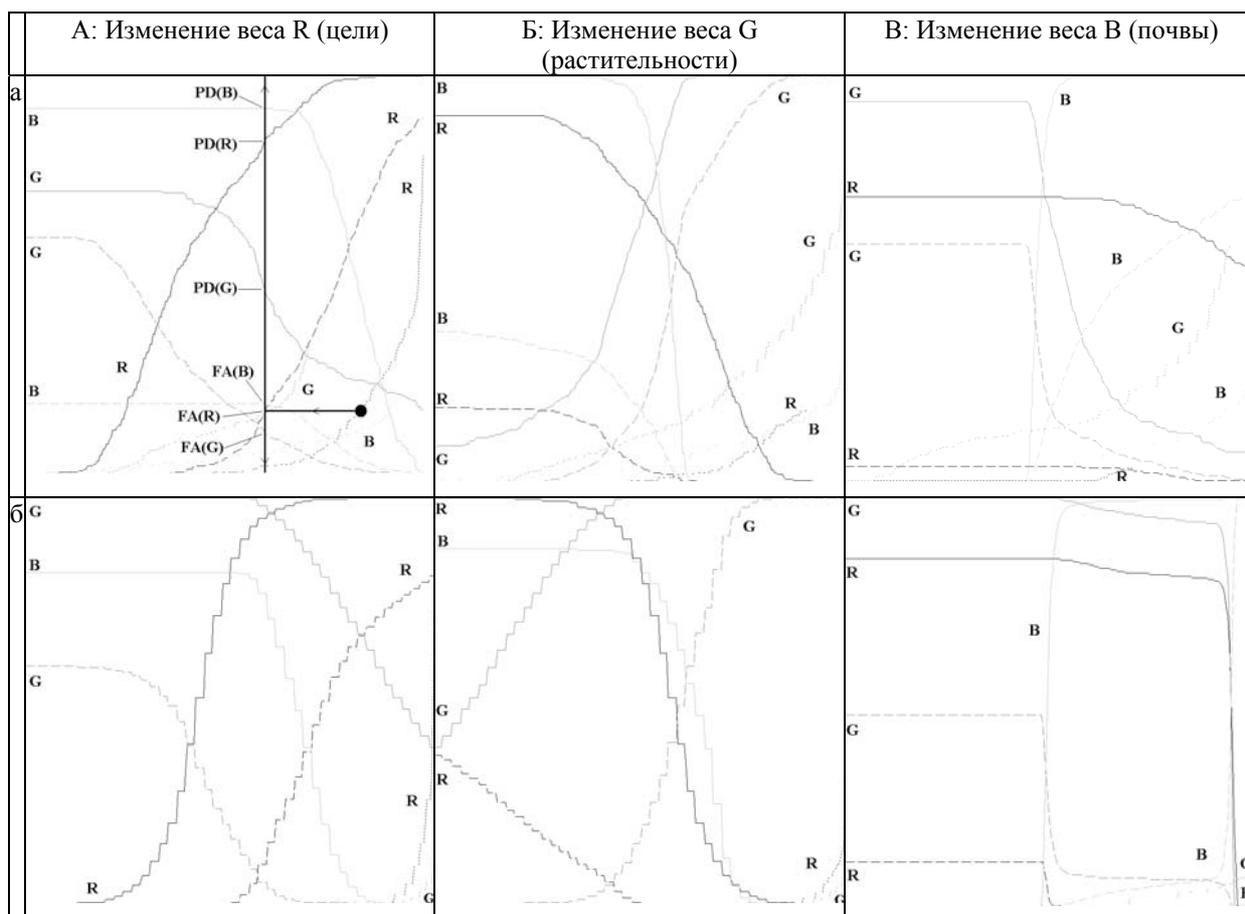


Рис. 12. Вероятности обнаружения PD (сплошная линия) и вероятности ложной тревоги FA (пунктирная линия) в зависимости от изменяемого веса одного из 3 объектов, а также кривая ошибок (точки): FA (ордината) от PD (абсцисса). Масштаб по обеим осям 0 – 1. R (черным), G (темно-серым) и B (светло-серым) – точности для 3 объектов: цели, растительного фона и почвы (а – для сканера, б – для гиперспектрометра). На первом рисунке показано, как, исходя из оптимизируемого критерия (в данном случае – PD=FA для объекта R – цели) выбирается значение веса (в данном случае – это вес того же объекта R)

Зависимость точности от спектрального разрешения гиперспектрометра

Спектральное разрешение изменялось путем сглаживания исходных данных скользящим окном разной ширины. Сглаживание проводилось одинаковым образом на обучающих и тестовых участках. Число каналов или сохранялось, или сокращалось: бралось по 1 каналу на окно.

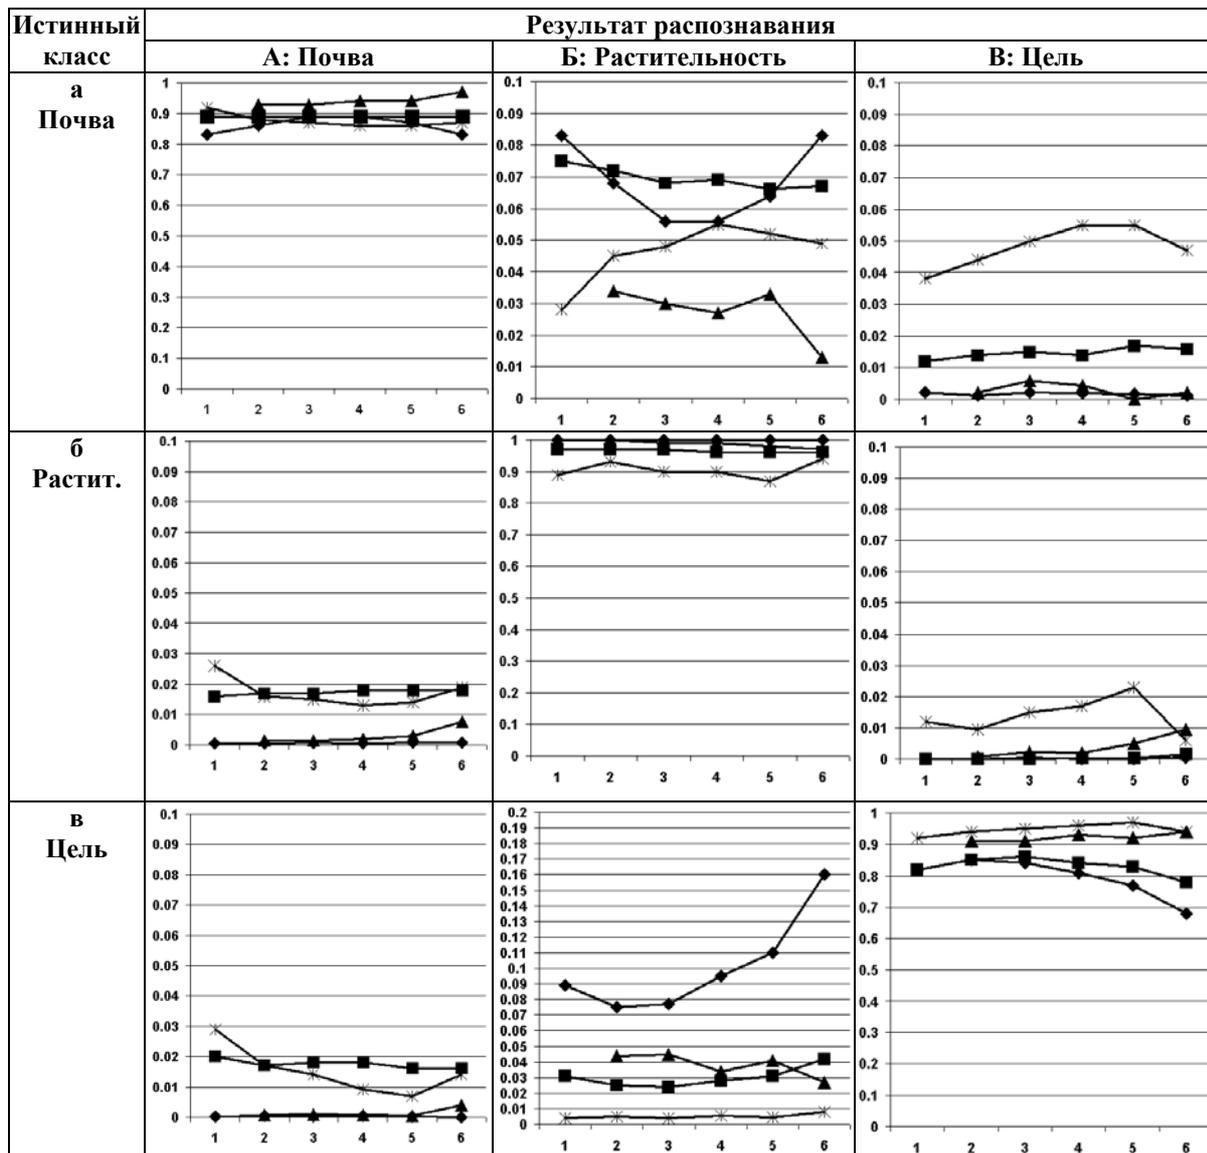
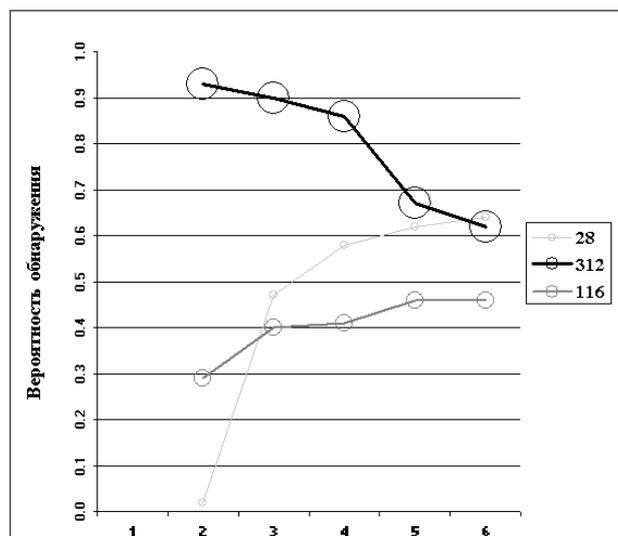


Рис. 13. Точности при окне спектрального сглаживания полушириной 0-4-8-15-30-60 каналов (цифры 1-6 по абсциссе). Обучение на «ядрах». Ромбы (без сокращения числа каналов) и треугольники (с сокращением числа каналов) – равные веса объектов, тест на участках а. Квадраты (без сокращения числа каналов) и звездочки (с сокращением числа каналов) - оптимизированные веса объектов, тест на участках в

Ожидаемое ухудшение точности с ухудшением спектрального разрешения для большинства объектов и показателей точности отсутствует. Для вероятности распознавания цели оно есть (хотя и небольшое) без сокращения каналов и – парадоксально – исчезает при сокращении каналов. Эта неожиданная ситуация требует объяснения. Для этого эксперименты были повторены с отдельными видами растительности, входящими в классы «Цель» и «Растительный фон» (Рис. 14).

А: Подклассы класса «Цель»



Б: Подклассы класса «Растительность»

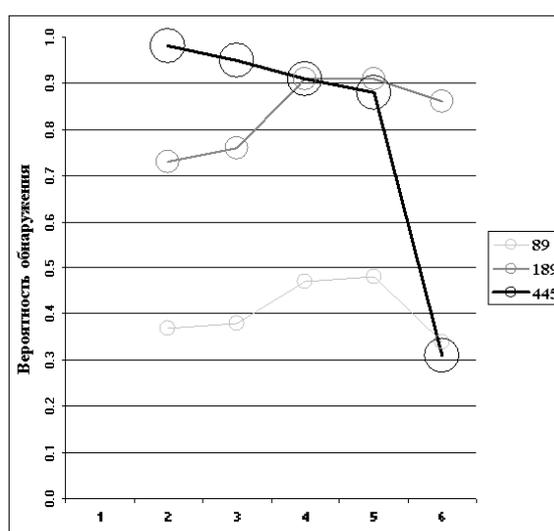


Рис. 14. Зависимость вероятности обнаружения для некоторых подклассов классов «Цель» и «Растительность» от уровня спектрального сглаживания (скользящее окно полушириной 0-4-8-15-30-60 каналов соответственно цифрам 1-6 по абсциссе) с сокращением числа каналов. Площади кружков пропорциональны числу пикселей класса в обучающих данных (указано в легенде). Обучение на «ядрах» (с разбивкой по подклассам), тест – на участках а

Видно, что для распознавания более тонких объектов спектральное разрешение более существенно, чем для «грубых» классов «цель» и «фон». Кроме того, подтверждается известный тезис о том, что убывание точности с нарастанием размерности данных связано с дефицитом обучающих данных [1]. Действительно, парадоксальная зависимость точности от спектрального разрешения более характерна для малых классов, а более крупные классы ведут себя «штатным» образом.

Зависимость точности от пространственного разрешения гиперспектрометра и сканера

Сглаживание производится двумерным окном полушириной от 0 до 60 пикселей. Рис. 15 показывает результаты. Снижение точности с ухудшением разрешения наиболее заметно для почвы. Оптимизация весов в целом (но не всегда) усиливает зависимость точности от разрешения. Разница по точности гиперспектрометра и сканера по большинству характеристик в пользу первого и если и зависит от разрешения, то немонотонно.

Выводы

Влияние выбора обучающих участков. Все методы чувствительны к попаданию в обучающий участок «не своих» объектов. Это больше всех других факторов снижает точность классификации. Существенны потери точности при переходе от обучающих участков к более крупным тестовым участкам. Это требует специальных пробных расчетов для оптимизации обучающих участков. Требуются значительные ручные усилия для построения качественных обучающих участков. Геометрическая точность может стать лимитирующим фактором за счет проблем, связанных с обучающими участками.

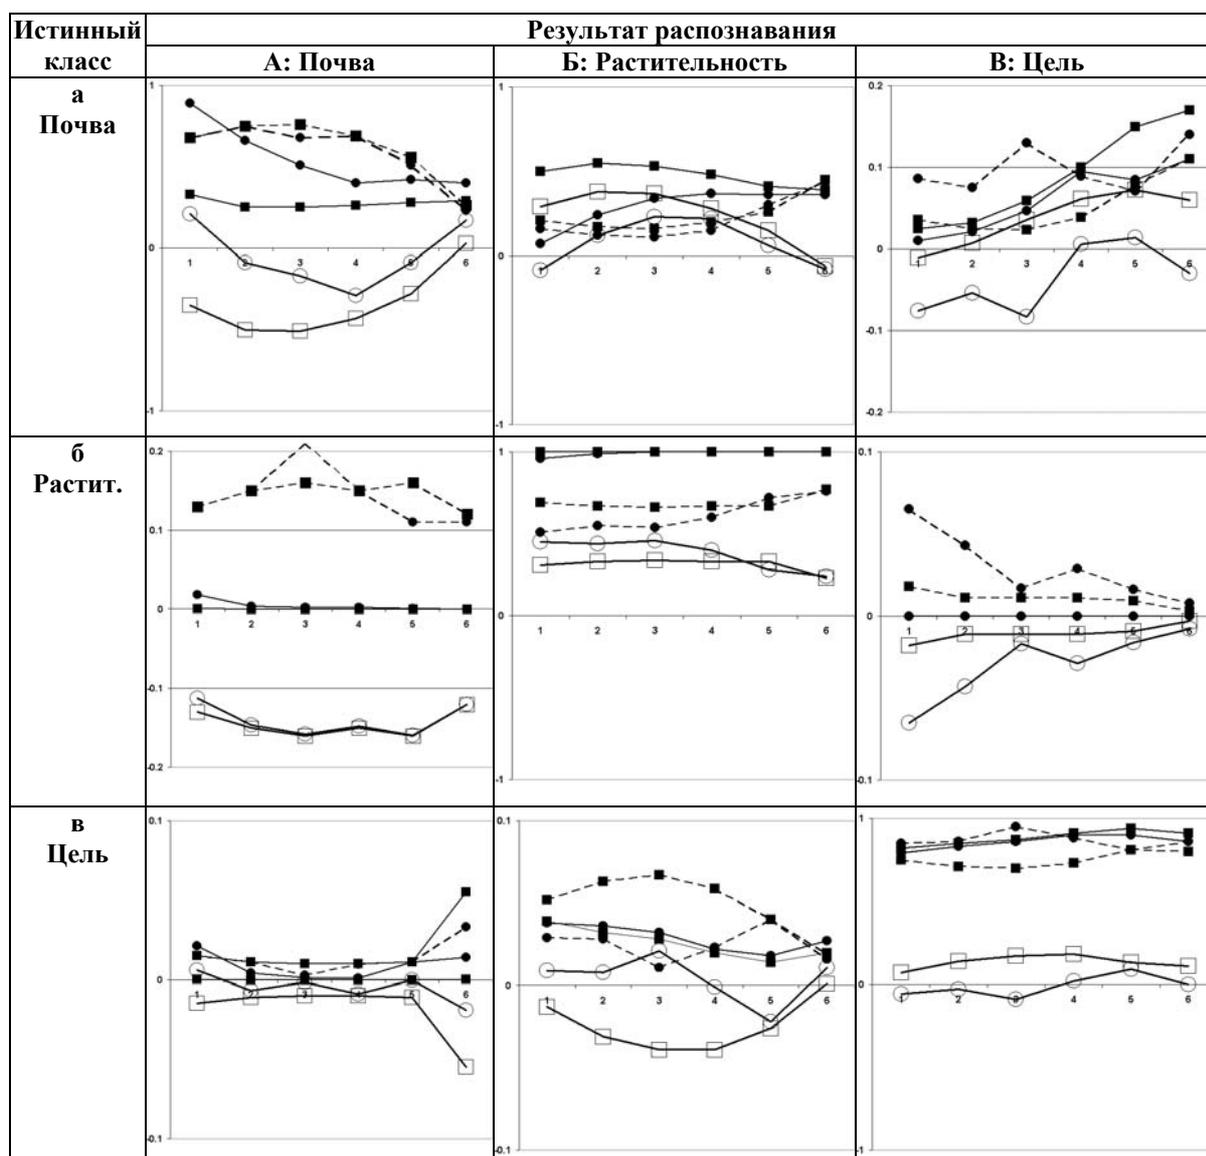


Рис. 15. Точности при пространственном окне сглаживания полушириной 0-4-8-15-30-60 пикселей (точки 1-6 вдоль абсциссы). Обучение на «ядрах», тест – на сплошных участках. Пунктир – сканер, сплошная линия – гиперспектрометр, сплошная линия с пустыми значками – разность «гиперспектрометр-сканер». Квадраты – равные веса объектов, кружки – оптимизированные веса объектов

Применимость кластеризации по Кохонену. Наилучшие перспективы у кластеризации – как у средства построения обучающих участков для метода МП. При этом проявляется высокая устойчивость результатов кластеризации к выбору исходных данных. Точность метода МП на таких участках по *некоторым* объектам заметно выше, чем на выбранных вручную участках. Кластеризацию можно применять итеративно для улучшения обучающих участков.

Применимость метода максимума правдоподобия. Метод МП позволяет планировать показатели точности путем выбора соответствующих весов объектов и порога отказа от классификации. Правда, эти показатели могут отклоняться от реальных точностей по мере ухода от обучающих участков. Важнейшая проблема в применении весов – выбор критериев, которыми измеряется точность: на какие показатели каких объектов ориентироваться, а какими пренебрегать.

Сравнение гиперспектрометра и сканера QuickBird. Метод МП дает на обучающих участках по большинству показателей стабильно более высокую точность для гиперспектрометра, чем для сканера. Это преимущество небольшое, но при переходе от обучающих участков к

большой территории оно увеличивается. Данные гиперспектрометра более устойчивы, чем данные сканера, к ошибкам в определении обучающих участков. Управляемость, измеряемая допустимым диапазоном выбора весов объектов в МП-классификации, выше для гиперспектрометра, чем для сканера.

Влияние пространственного и спектрального разрешения на точность классификации. Влияние ухудшения *спектрального* разрешения на точность МП-классификации меньше, чем ожидалось, и иногда имеет парадоксальный характер: с ухудшением разрешения некоторые показатели точности растут. Этот эффект, видимо, исчезает для более тонких объектов – видов растительности (внутри цели или фона). Влияние ухудшения *пространственного* разрешения на точность МП-классификации также иногда имеет парадоксальный характер. Возможно, это частично связано с большой разницей продольного и поперечного разрешения в данных гиперспектрометра. При использовании адаптивных весов в методе МП зависимость от разрешения становится более «нормальной». Разные точностные показатели ведут себя совершенно по-разному при изменении как спектрального, так и пространственного разрешения. Гиперспектрометр и сканер ведут себя примерно одинаково с изменением пространственного разрешения, при том, что по большинству показателей точность гиперспектрометра выше, чем сканера, при любом разрешении.

Литература

1. *Landgrebe D.* Information Extraction Principles and Methods for Multispectral and Hyperspectral Image Data // Information Processing for Remote Sensing, ed.C. H. Chen, World Scientific Publishing Co., Inc., 2000.