

УДК 528.8.042:630\*18

## **The Problems of Airborne Hyperspectral Monitoring of Soil and Vegetation Cover**

**Egor V. Dmitriev<sup>\*a</sup> and Vladimir V. Kozoderov<sup>b</sup>**

*<sup>a</sup>Institute of Numerical Mathematics RAS  
8 Gubkin Str., Moscow, 119333, Russia*

*<sup>b</sup>Lomonosov Moscow State University  
GSP-1, Leninskie Gory, Moscow, 119991, Russia*

Received 28.03.2015, received in revised form 20.11.2015, accepted 03.12.2015

---

*The problem of remote sensing of soil and vegetation cover using airborne hyperspectral cameras is considered. The modern state of development of airspace measuring instruments with high spectral resolution is analyzed. The problems and solution methods of the thematic processing of hyperspectral images are discussed. Applications of the optimal Bayesian classification for the recognition of the forest stand species are investigated. The method of the effective reduction of the dimensionality of the feature space is proposed. The classification accuracy for the selected test areas is estimated.*

*Keywords: remote sensing, hyperspectral measurements, aerospace images. pattern recognition, vegetation cover.*

*DOI: 10.17516/1999-494X-2015-8-8-1083-1095.*

---

## **Проблемы гиперспектрального авиационного мониторинга почвенно-растительного покрова**

**Е.В. Дмитриев<sup>а</sup>, В.В. Козодеров<sup>б</sup>**

*<sup>а</sup>Институт вычислительной математики РАН  
Россия, 119333, Москва, Губкина, 8*

*<sup>б</sup>Московский государственный университет им. М.В. Ломоносова  
Россия, 119991, Москва, Ленинские горы, 1*

---

*Рассматривается задача дистанционного зондирования почвенно-растительного покрова с использованием авиационных гиперспектрометров. Приводится анализ современного*

*развития аэрокосмической измерительной аппаратуры высокого спектрального разрешения. Обсуждаются проблемы и методы тематической обработки гиперспектральных данных. Исследуются возможности использования оптимальной байесовской классификации для распознавания породного состава лесной растительности. Предлагается методика эффективного сокращения размерности признакового пространства. Приводятся оценки точности классификации для выбранных участков тестовой территории.*

*Ключевые слова: проблемы гиперспектрального авиационного мониторинга почвенно-растительного покрова.*

---

## 1. Введение

Основу существующих систем глобального и регионального мониторинга объектов на поверхности Земли составляют данные дистанционного зондирования. Используемая при этом измерительная аппаратура, установленная на авиационные и космические летательные аппараты, позволяет получать изображения в различных спектральных диапазонах, которые принято разделять на многоспектральные и гиперспектральные. Многоспектральные изображения представляют собой набор монохромных изображений в отдельных спектральных каналах, отстоящих друг от друга на расстояниях, превышающих их полуширину. Каналы гиперспектральных приборов пересекаются и, таким образом, непрерывно покрывают рабочий спектральный диапазон.

В настоящее время существует достаточно широкий набор гиперспектральных систем аэрокосмического зондирования разных производителей с числом спектральных каналов от нескольких десятков до нескольких сотен [1]. Следует отметить, что области практического применения гиперспектральных измерений не ограничиваются задачами ДЗ. Эти измерения эффективно применяются и для других целей (медицина, археология, оценка состояния продуктов питания и т.п.). Число приложений непрерывно растет. Например, в США данные оперативных гиперспектральных аэрокосмических измерений используются даже для «точного земледелия» по выявлению неоднородностей отдельных сельскохозяйственных полей, управлению работой механических систем (тракторов, комбайнов и др.) в части внесения необходимых норм удобрений на локальных полях, ирригации, борьбе с насекомыми-вредителями [2].

Гиперспектральные системы ДЗ находят широкое применение при мониторинге земель, лесных и водных ресурсов, поиске месторождений полезных ископаемых, оценке экологической обстановки, контроле геотехнических сооружений (трубопроводов, линий электропередач, гидрологических объектов и др.). При этом возникают технические сложности накопления больших объемов гиперспектральных данных, разработки алгоритмов их использования.

Приложения данных гиперспектрального аэрокосмического зондирования в природопользовании развивались в направлении решения экологических, геологических, лесоинвентаризационных задач. Особенности решения экологических задач связаны с рассмотрением стрессового состояния растительности при наличии загрязнений почвенного покрова. Значительная часть исследований разных видов растительности традиционно сосредоточена в спектральной области 0.4-1.1 мкм. Обычно эта область называется видимой и ближней инфракрасной областью (visual and near infrared region/VNIR). Обоснована необходимость расширения этой

спектральной области в упомянутую выше область коротковолновых инфракрасных каналов (SWIR) в сравнении с областью VNIR.

Отметим следующие научные и прикладные задачи, решаемые с помощью данных гиперспектрального зондирования: улучшение информационного содержания спектральных данных в процессе обнаружении стрессового состояния растительности [3]; оценка содержания хлорофилла в растениях [4]; идентификация малых различий в проективном покрытии вегетирующей растительности [5]; изучение биохимических характеристик, таких как содержание азота в растениях [6]; различение разных типов растительного покрова [7]; изучение вариации влажности сельскохозяйственных посевов [8]; концентрация пигментов листьев растений [9]; моделирование количественных характеристик урожайности сельскохозяйственных культур [10]; улучшение обнаружения изменений в разреженной растительности [11].

Имеются публикации [12], доказывающие, что спутниковая аппаратура высокого спектрального разрешения позволяет восстанавливать структуру тропических лесов с более высокой точностью, чем данные аппаратурных комплексов TM и HRV (High-Resolution Visible) спутника SPOT. В работе [13] показано, что различия в значениях влажности и градиентов топографии тропических лесов определяются с более высокой точностью по данным 6-канальной аппаратуры «Усовершенствованный тематический картограф» (Enhanced Thematic Mapper plus/ETM+) с пространственным разрешением около 30 м в сравнении с 4-канальной аппаратурой спутника IKONOS, имеющей пространственное разрешение около 4 м. Реализация этих новых возможностей связана с наличием коротковолновых инфракрасных каналов (short-wave infrared/SWIR) у аппаратуры ETM+, что позволило объяснить около 20 % изменчивости биохимических характеристик лесов.

## 2. Аппаратура гиперспектрального мониторинга

В ходе развития систем аэрокосмического мониторинга наряду с известными спектрорадиометрами MODIS и ETM+, имеющими четыре канала в видимом и ближнем инфракрасном диапазоне (ВБИК, 400-900 нм) при пространственном разрешении 500 и 30 м соответственно, появляются новые приборы, позволяющие получать значительно более подробные данные. Так, например, сенсор Hyperion, установленный на спутнике EO-1 (Earth Observing-1), имеет около 80 каналов ВБИК-диапазона при пространственном разрешении 30 м, а аппаратура спутника GEOEYE-2 имеет пространственное разрешение 1.65 м для четырех мультиспектральных каналов и 0.25 м для панхроматического канала.

Задача создания новых систем гиперспектрального космического мониторинга во ВБИК-диапазоне имеет высокую актуальность во всех ведущих странах мира. Так, например, в Японии был разработан прибор HISUI (Hyperspectral Imager Suit), представляющий собой комбинацию мультиспектрального и гиперспектрального сканеров. Мультиспектральный сканер имеет четыре спектральных канала в диапазоне 450-890 нм. Полоса захвата составляет 90 км, пространственное разрешение – 5 км. Характеристики гиперспектрометра HUSUI сопоставимы с Hyperion. Прибор имеет 185 каналов, покрывающих диапазон от 400 до 2500 нм (57 каналов ВБИК-диапазона), полосу захвата 30 км и пространственное разрешение 30 м. Запуск HUSUI планируется осуществить в 2016 г. В том же году в рамках программы EnMAP (Environmental Mapping and Analysis Program) будет выведен на орбиту германский гиперспектрометр, раз-

работанный компанией «Кайзер-Треде» (Kaysers-Threde GmbH), имеющий 89 каналов ВБИК-диапазона и пространственное разрешение 30 м. Также следует отметить итальянский гиперспектрометр PRISMA, имеющий 249 каналов (92 во ВБИК-диапазоне), планируемый к запуску в 2017 г. В 2020 г. будет запущен гиперспектрометр HypSIRI производства США, имеющий 213 каналов в диапазоне 380-2500 нм и пространственное разрешение 60 м совместно со спектро-радиометром теплового диапазона.

Для получения более детальной региональной информации применяют видеоспектрометры, установленные на воздушные летательные аппараты. Относительно низкая высота полета обеспечивает возможность совмещения высокого пространственного и спектрального разрешения и позволяет существенно уменьшить искажающее влияние атмосферы. В качестве примера наиболее известных зарубежных сканеров можно привести AisaEAGLET (Spectral Imaging Ltd, Финляндия) и CASI-1500, (ITRES Research Ltd, Канада), которые имеют, соответственно, до 820 и 288 каналов во ВБИК-диапазоне при пространственном разрешении примерно 0.4 м при визировании в надир с высоты 1 км (табл. 1).

Отечественные системы аэрокосмического мониторинга также активно развиваются в последние годы, хотя и с некоторым отставанием. Один из лучших образцов действующих отечественных сканеров, установленный на спутнике «Ресурс-ДК1», имеет пространственное разрешение 2-3 м (эллиптическая орбита) и три канала во ВБИК-диапазоне. Сканер космического аппарата «Канопус-В» имеет четыре канала в данном диапазоне с разрешением 10.5 м. В 2012 г. на базе МКА-ФКИ был выведен на орбиту пробный образец российского гиперспектрометра производства НПО «Лептон» (г. Зеленоград, г. Москва).

Известные отечественные авиационные гиперспектрометры (табл. 1), такие как «Сокол-ГЦП» (ФНПЦ ОАО Красногорский завод им. С.А. Зверева, г. Красногорск, Московской обл.),

Таблица 1. Основные характеристики зарубежных и российских гиперспектрометров

Название прибора	AisaEAGLET	CASI1500	Сокол-ГЦП	Реагент	АВ-ВД
Производитель	Spectral Imaging Ltd., Finland	ITRES Research Ltd, Canada	ОАО КМЗ, Красногорск, Моск. обл.	ЗАО НТЦ Реагент, Москва	НПО Лептон, Зеленоград, Москва
Рабочий диапазон, нм	400-1000	380-1050	530-1000	450-800	400-1000
Число каналов	820	288	105	106-250	287
Спектральное разрешение, нм	3.3	2.4	4.6-7.1	1.6-16	0.5-15
Объединение каналов	да	да	нет	нет	нет
Калибровка	да	да	да	–	да
Простр. разр., м (высота 1 км)	0.053-0.4	0.4	0.75	1.4	0.56
Полоса захвата (пиксели)	1600	1500	–	250	500
Разрядность, бит	12	14	14	14	12
Вес, кг	3.5 (10.5 общ.)	25 (43 общ.)	(50 общ.)	–	2
Мощность, Вт	100	–	250	7-12	7

«Реагент» (ЗАО «НТЦ Реагент», Москва) АВ-ВД (НПО «Лептон»), имеют схожие характеристики и уступают по ряду параметров ведущим западным образцам. В качестве диспергирующего элемента используются многокомпонентные призмы. Разрешение спектральных каналов существенно увеличивается при движении в фиолетовую область спектра. Этот факт существенно затрудняет съемку, а именно выбор времени накопления, поскольку измерения в узких спектральных каналах фиолетовой и синей областей содержат в основном шум, и в то же самое время более широкие каналы БИК-области склонны к насыщению при измерениях растительного покрова. Таким образом, эффективное число каналов уступает западным приборам. Пространственное разрешение зарубежных приборов также несколько выше, чем у российских. Представленные отечественные гиперспектрометры не позволяют производить объединение каналов на аппаратном уровне. Доступ к информации, касающейся технических характеристик, имеющихся дисторсий и используемых методик калибровки, ограничен.

### 3. Летные испытания аппаратуры НПО «Лептон»

На протяжении последних лет гиперспектрометры производства НПО «Лептон» испытывались на базе технопарка Тверского государственного университета. Так, в августе 2011 г. была проведена очередная кампания авиационных измерений, в ходе которой были получены перекрывающиеся гиперспектральные изображения, покрывающие тестовый участок размером 4x10 км, расположенный на территории Савватьевского лесничества Тверского лесхоза (рис. 1). Породный состав леса на тестовой территории имеет в основном древостои сосны и

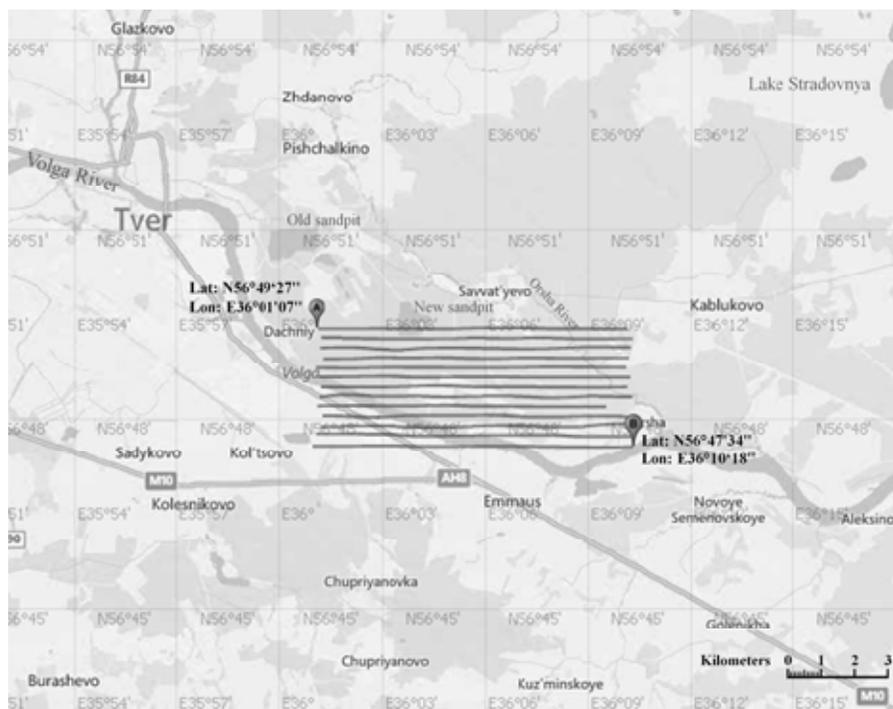


Рис. 1. Тестовый регион проведения измерительной кампании. Серыми линиями между точками А и В обозначены 13 треков авиационной гиперспектральной съемки

березы различных возрастных классов. В небольшом количестве присутствуют также осинники и ельники. Наземная информация по распределению породного и возрастного состава представлена стандартными табличными и картографическими данными лесотаксации.

Для проведения съемок использовался самолет Ан-2. Полет проводился полностью в ручном режиме, для выполнения полетных заданий пилот применял GPS-навигатор, при этом обеспечивалась точность 30-80 м в зависимости от локальных метеорологических условий. Измерения проводили гиперспектрометром АВ-ВД разработки НПО «Лептон» (см. табл. 1) и зеркальной фотокамерой, установленными на гиостабилизированную платформу JSM-3000.

Перед полетом гиперспектрометр проходит серию специальных тестов, заключающихся в определении интервала линейности текущей калибровки и зависимости уровня шума от уровня сигнала. Первый тест позволяет установить оптимальное для текущих условий время накопления, обеспечивающее наилучшую точность измерения спектральной плотности энергетической яркости (СПЭЯ). При слишком малом времени накопления, измеряемые СПЭЯ, существенно возмущаются собственным шумом ПЗС-матрицы, а при слишком большом – данные калибровки ГСК становятся недействительными из-за нелинейных эффектов. Второй тест позволяет определить эффективное радиометрическое и радиационное разрешение ГСК. Так, для описанной выше кампании измерений было установлено, что спектральное разрешение должно быть редуцировано к значению из диапазона от 5 до 30 нм посредством объединения каналов.

#### 4. Методика классификации гиперспектральных данных

Спектральные характеристики изучаемых объектов зависят от многих факторов. Лесной полог является довольно сложным объектом с изменчивой отражательной способностью. Даже при однородном породном и возрастном составе древостоя соответствующие спектры будут определяться объемным распределением листвы и ветвей, вариациями отражающей способности листьев, ветвей и подстилающей поверхности и соотношением указанных элементов. Поскольку на практике нет точной информации о процентном соотношении элементарных компонент и их взаимном пространственном расположении, то формирование спектра пикселя гиперспектрального прибора имеет существенно случайный характер. Таким образом, для построения алгоритмов классификации вполне естественно использовать вероятностный подход.

Пусть  $x \in X$  – элемент множества признаков, а  $y \in Y$  – элемент множества наименований классов. Пусть также имеется случайная выборка (обучающее множество)  $\Omega^N = \{x(i), y(i)\}_{i=1}^N$  объема  $N$  из множества  $\Omega = X \times Y$ . Построение алгоритма обучаемой классификации  $a(x)$ , действующего из  $X$  в  $Y$ , сводится к разбиению признакового пространства на непересекающиеся области, каждая из которых ставится в соответствие одному из классов. Алгоритм должен быть оптимален в некотором смысле на  $\Omega^N$ . В рамках вероятностного подхода требуется построить алгоритм, который приводит к минимальной вероятности ошибки классификации (байесовский алгоритм).

Общий вид байесовского классификатора представляется выражением

$$a(x) = \arg \max_{y \in Y} P_y p_y(x), \quad (1)$$

где  $P(y) \equiv P_y$  – вероятность класса  $y$  на рассматриваемой сцене (априорная вероятность класса);  $p(x | y) \equiv p_y(x)$  – плотность вероятности распределения признаков внутри класса  $y$  (функция правдоподобия класса). Обучение алгоритма (1) состоит в оценке неизвестных  $P_y$  и  $p_y(x)$  на основе  $\Omega^N$ .

Параметрический подход к обучению предполагает, что функция плотности вероятности известна с точностью до параметров –  $p(x) = \varphi(x, \theta)$ , т.е. задано параметрическое семейство распределений  $\Phi^\theta$ . В этом случае обучение классификатора сводится к оценке параметров  $\theta$ .

Классический подход [14] состоит в предположении, что  $p_y(x)$  принадлежат семейству нормальных распределений  $N(\mu, \Sigma)$  и известен как нормальный дискриминантный анализ. При поиске максимума апостериорной вероятности можно использовать монотонные преобразования. В рассматриваемом случае удобно использовать логарифмирование. Таким образом, алгоритм (1) преобразуется к виду  $a(x) = \arg \max_{y \in Y} (\ln P_y + \ln p_y(x))$ . Подставляя функцию плотности многомерного нормального распределения, имеем алгоритм

$$a(x) = \arg \max_{y \in Y} \left( \ln(P_y) - \frac{1}{2} (x - \hat{\mu}_y)^T \hat{\Sigma}_y^{-1} (x - \hat{\mu}_y) - \frac{1}{2} \ln(\det(\hat{\Sigma}_y)) \right), \quad (2)$$

известный как квадратичный дискриминантный анализ. Название связано с тем, что дискриминантные поверхности, разделяющие каждую пару классов, задаются полиномами 2-й степени.

Если для алгоритма (2) предположить, что ковариационные матрицы  $\Sigma_y$  имеют диагональный вид, то говорят о квадратичном наивном байесовском классификаторе, алгоритм которого совпадает с (2) с тем различием, что ковариационные  $\Sigma_y^{-1}$  и  $\det(\Sigma_y)$  рассчитываются гораздо более просто и устойчиво. При совпадении ковариационных матриц для различных классов имеем линейный байесовский классификатор.

Описанные выше классические подходы соответствуют довольно грубым параметрическим моделям и не обладают достаточной гибкостью. Начнем с того, что выбор дискриминантной поверхности в виде гиперплоскости, параболоида, гиперболоида и т.п. приводит к экстраполяции. Признаки, находящиеся далеко от значений в обучающей базе данных, скорее всего, будут относиться к некоторой иной, неизвестной группе объектов. Таким образом, необходимо использовать только поверхности, ограничивающие некоторую конечную область в признаковом пространстве. Для этого в алгоритме (1) дополнительно применяется условие

$$\max(p_y) < P_{\min},$$

что позволяет ввести класс «прочие объекты». В этом случае дискриминантная поверхность для каждого отдельного класса будет представляться гиперэллипсоидом.

В реальности оптимальная дискриминантная поверхность, как правило, плохо аппроксимируется одним гиперэллипсоидом, но может быть приближена их совокупностью. Для этого вместо многомерного нормального распределения можно использовать модель гауссовских смесей

$$p(x | \{w_i(y), \mu_i(y), \Sigma_i(y)\}_1^K) = \frac{1}{\sqrt{(2\pi)^{N_x}}} \sum_{i=1}^K \frac{w_i(y)}{\sqrt{\det(\Sigma_i(y))}} \exp \left[ -\frac{1}{2} (x - \mu_i(y))^T \Sigma_i^{-1}(y) (x - \mu_i(y)) \right],$$

где  $K$  – число компонент смеси;  $w_i$ ,  $\mu_i$ , и  $\Sigma_i$  – соответственно весовой коэффициент, вектор математических ожиданий и ковариационная матрица  $i$ -й компоненты. Оценки параметров  $w$ ,  $\mu$ , и  $\Sigma$  получаются на основе априорной информации как решение задачи максимизации правдоподобия  $F_x(w, \mu, \Sigma) = \ln p(x | \{w_i(y), \mu_i(y), \Sigma_i(y)\}_1^K)$ . Для этого может быть использован EM-алгоритм.

Помимо оценки плотностей распределения признаков внутри классов для обучения алгоритма (1) нам необходимо получить оценки априорных вероятностей классов. Задание априорных вероятностей является своеобразным процессом настройки «жесткости» отбора признаков, производимой классификатором для того или иного класса. Так, например, если данный класс дискриминируется эллиптической поверхностью, то увеличение априорной вероятности данного класса эквивалентно приводит к ее пропорциональному увеличению всех осей.

Априорные вероятности могут быть заданы на основе предположений, например, объект «песчаная почва» появляется на данной сцене с вероятностью в 3 раза больше, чем объект «торфяная почва», либо вычислены на основе априорной информации, например по частотам вхождения классов в обучающую выборку. Последнее в нашем случае делать крайне опасно, поскольку обучающие спектры получаются на основе оконтуривания соответствующих объектов, что является независимой выборкой лишь относительно данного класса, но никак не относительно всей сцены.

В нашем случае априорные вероятности задаются по результатам текстурной классификации. Это позволяет с меньшей вероятностью допустить грубую ошибку при распознавании основных типов объектов. Для пикселей, которые были классифицированы на основе текстурного анализа с предположительно низкой точностью, априорные вероятности задаются одинаковыми для всех классов.

## 5. Выбор спектральных каналов

При увеличении размерности признакового пространства и числа компонент гауссовской смеси происходит также увеличение числа оцениваемых статистических параметров. Поскольку мы имеем конечное число реализаций для оценки данных параметров, может возникнуть проблема, известная как «проклятие размерности», состоящая в том, что алгоритм будет с высокой точностью классифицировать элементы из  $\Omega^N$  и прочие элементы (из  $\Omega \setminus \Omega^N$ ) – с низкой точностью. Таким образом, многокомпонентные гауссовские смеси могут применяться только при наличии достаточно большого обучающего ансамбля для каждого класса.

Одним из методов решения проблемы «проклятия размерности» является отбор наиболее информативных признаков. Для этого можно использовать пошаговый метод «последовательного дополнения» (step up method). Суть метода заключается в следующем. Выбирается метод распознавания и априорная вероятность для распознаваемых классов. Пространство всех признаков делится на две группы – принятых в модель и остальных признаков (для которых производится оценка возможности принятия в модель). Для каждого признака из множества «остальных признаков» делается оценка ошибки распознавания при условии его добавления в модель. Из полученного набора ошибок выбирается минимальная и производится ее сравнение с ошибкой предыдущей модели. Если произошло значимое уменьшение ошибки, то соответствующий признак принимается в модель, если нет, то процесс останавливается.

В нашей задаче контроль остановки цикла может осуществляться двумя способами.

1. Проверка значимости различия ошибок на текущем и предшествующем шагах на основе параметрического метода (на основе нормального распределения), проверка гипотезы о равенстве эмпирических частот. Уровень значимости 0.1.

2. Оценка максимально возможного числа используемых признаков – цикл продолжается до тех пор, пока оценка полной вероятности ошибки распознавания уменьшается. Метод основан на том, что при наличии достаточного количества незначимых признаков неизбежно возникнут биения оценки ошибки распознавания. Этот метод позволяет оценить верхнюю границу числа используемых признаков, потенциально полезных для распознавания.

Стандартный пошаговый метод, как правило, приводит к неустойчивому результату, т.е. малые изменения обучающего ансамбля влекут за собой существенные изменения выбранной последовательности каналов. Мы предложили модификацию данного метода, которая позволяет в значительной мере избежать данной проблемы.

Метод состоит в следующем (рис. 2). На первом этапе выделяется главный спектральный канал, который обеспечивает точное распознавание наибольшего числа рассматриваемых классов. Далее производится серия запусков пошагового метода выбора каналов. При каждом запуске обучающий ансамбль случайным образом разделяется на две приблизительно равных части, одна часть используется для оценки параметров, вторая – для оценки ошибок классификации. В результате данного процесса получаем набор последовательностей выбранных каналов. На конечном этапе из данного набора выбирается наиболее вероятная последовательность.

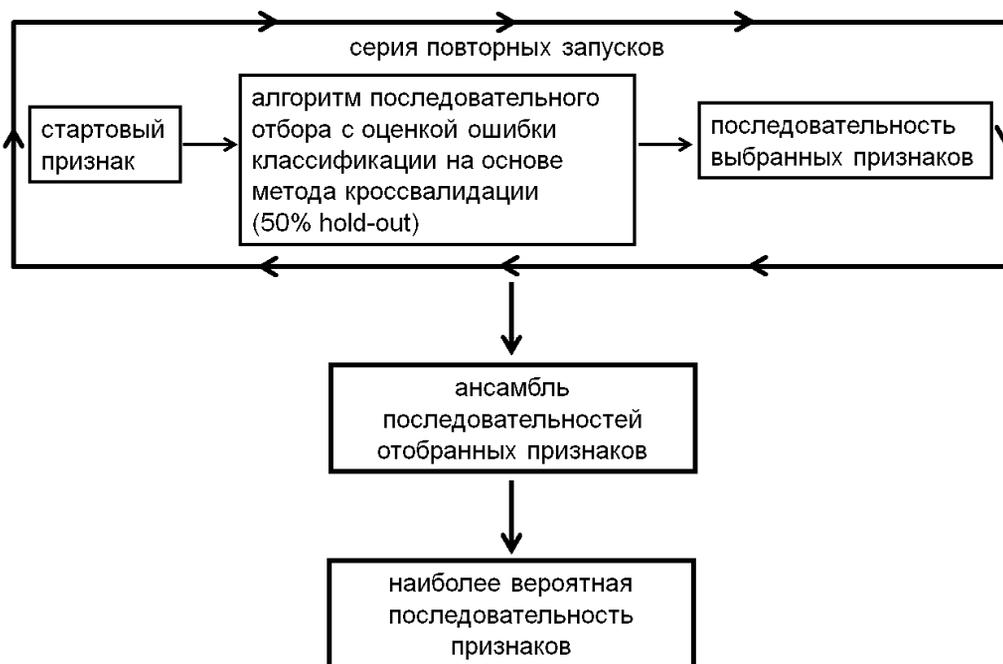


Рис. 2. Регуляризованный метод отбора наиболее информативных признаков

## 6. Численные эксперименты

Описанные выше методы были использованы для обработки гиперспектральных изображений, полученных в ходе кампании 2011 г. на территории Тверского лесхоза. Решалась задача классификации породного состава смешанных древостоев. Для составления базы данных обучающих спектров нас интересовали только выделы с однородным породным составом. Таким образом, были получены достаточно большие выборки для сосны, березы, осины и вяза.

Изображения лесного полога имеют характерную текстуру, которую составляют перемежающиеся освещенные и затененные участки крон, а также межкрупные просветы. СПЭЯ отраженного излучения освещенных участков определяется в основном оптическими свойствами кроны, текущими атмосферными условиями и высотой солнца. При этом гиперспектрометр обеспечивает достаточно хорошее соотношение сигнал/шум.

Отражение затененными участками крон происходит гораздо более сложным образом. Здесь начинает играть роль многократное рассеяние света внутри кроны и спектральные свойства подстилающей поверхности. Кроме того, уровень сигнала гиперспектрометра значительно ниже и влияние собственной шумовой составляющей на формирование СПЭЯ отраженного излучения гораздо более существенно, чем для освещенной части кроны.

Освещенные и затененные участки кроны могут быть разделены на основе значений интегральной яркости (СПЭЯ интегрируется методом трапеций по всем центральным длинам волн измерительных каналов). Для полученных обучающих выборок были рассчитаны интегральные яркости и разделены на три градации с помощью процентных интервалов. Указанный метод работает следующим образом. Отрезок от 0 до 1 делится на заданное число равных частей. Затем рассчитывается эмпирическая функция распределения вероятностей и реализация, попавшая в один из интервалов, относится к соответствующей градации.

На основе полученных данных были проведены численные эксперименты по распознаванию породного и возрастного состава древостоев на тестовом участке. На рис. 3 приведена матрица ошибок классификации для выбранных возрастов березовых и сосновых насаждений, которые соответствуют основным возрастным классам. Оценка точности решения задачи распознавания, полученная методом кросс-валидации, находится в пределах 80-88 % для березняков и 95-99 % – для сосняков. Распознавание всей совокупности возрастов (на примере сосняков от 13 лет до 136 лет с шагом 10 лет) по данным самолетного гиперспектрального зондирования приводит к более существенным ошибкам.

Результаты алгоритма отбора наиболее информативных спектральных каналов представлены в табл. 2. В качестве главного канала был выбран канал ближнего инфракрасного диапазона с центральной длиной волны 790.39 нм. Рассмотрены различные задачи классификации, связанные с распознаванием сосновых и березовых древостоев различных возрастных групп с учетом освещенности крон.

Длина полученных оптимальных последовательностей составила от 4 до 7 спектральных каналов. Повторные запуски алгоритма позволили выяснить, что наиболее информативные каналы, лежащие в начале последовательности, определяются устойчиво. При этом возможна неопределенность выбора между двумя соседними каналами. Каналы, изменяющиеся случайным образом при повторных запусках алгоритма, выделены серым цветом. Полученная неустойчивость связана с достаточно мягким критерием остановки алгоритма пошагового отбора.

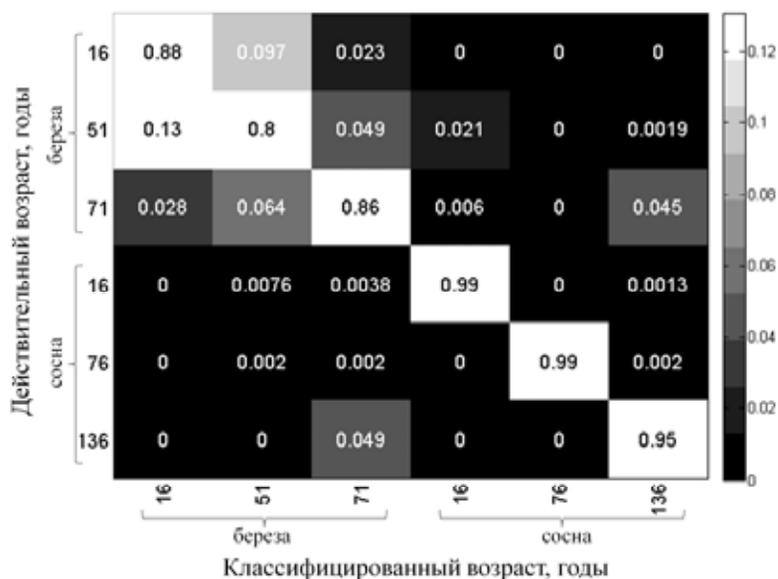


Рис. 3. Матрица ошибок (вероятности) для полностью освещенных Солнцем участков крон чистых березовых (возраст 16, 51 и 71 год) и сосновых выделов (возраст 16, 76 и 136 лет) на выбранных участках наземных обследований тестовой территории

Таблица 2. Результаты оптимизации спектральных каналов для различных задач классификации. Приведены номера каналов (НК) и центральные длины волн (ЦДВ)

Сосна, береза осина; молодняк; освещенные кроны							
НК	64	25	46	18	43		
ЦДВ, нм	790.39	534.89	662.34	495.93	642.78		
Сосна, береза осина; молодняк; затененные кроны							
НК	64	23	47	53	25	49	9
ЦДВ, нм	790.39	523.59	669.38	719.08	534.89	684.40	446.60
Сосна, береза осина; спелый древостой; освещенные кроны							
НК	64	70	85	1			
ЦДВ, нм	790.39	834.91	990.02	404.21			
Сосна, береза осина; спелый древостой; затененные кроны							
НК	64	43	66	1			
ЦДВ, нм	790.39	642.78	804.37	404.21			
Сосна; возрастной состав, освещенные кроны							
НК	64	53	35	81	52	24	47
ЦДВ, нм	790.39	719.08	595.69	941.27	709.75	529.10	669.38
Береза; возрастной состав, освещенные кроны							
НК	64	52	17, 18	47, 48	30	50	
ЦДВ, нм	790.39	709.75	495.93, 490.36	676.72, 669.38	564.14	692.44	

Неустойчивые каналы имеют наименьшую информативность в указанных последовательностях и не оказывают существенного влияния на решение.

Необходимо отметить, что полученные последовательности могут измениться при использовании другого рода классификаторов. По данным табл. 2 можно видеть, что для решения указанных задач необходимо использовать самые разнообразные каналы видимого и ближнего инфракрасного диапазона. Поэтому если требуется решать совокупность этих задач, то целесообразно использовать данные гиперспектральных измерений. Кроме того, в ходе дальнейших исследований длина последовательностей может быть увеличена за счет привлечения дополнительной обучающей информации.

## 7. Заключение

Описаны проблемы, возникающие при разработке систем аэрокосмического гиперспектрального мониторинга почвенно-растительного покрова. Предложена методика распознавания породного состава древостоев, основанная на принципе оптимальной байесовской классификации. Показано, что для обеспечения устойчивости алгоритмов классификации необходимо оптимизировать признаковое пространство путем отбора наиболее информативных спектральных каналов. Предложена методика повышения устойчивости стандартной процедуры выбора наиболее информативных спектральных каналов гиперспектромера. Стандартный метод состоит в последовательном добавлении в классификатор каналов с наибольшей условной информативностью до тех пор, пока вносимое увеличение точности не перестанет быть значимым. Результат данного метода существенно меняется при малых изменениях обучающих множеств. Предложенный новый метод дает возможность добиться устойчивости такого выбора. Методика позволила сформировать оптимальные наборы каналов для различного типа древостоев.

***Работа выполнена при финансовой поддержке грантов РФФИ 13-01-00185, 14-05-00598, 14-07-00141.***

## Список литературы

- [1] Gut N. *Spectroscopy*, 1999, 14(3), 28-42.
- [2] Johnson B.D. *Photonics Spectra*, 2002, 1, 1-4.
- [3] Carter G.A. *International Journal of Remote Sensing*, 1994, 15(3), 697-703.
- [4] Blackburn G.A. *International Journal of Remote Sensing*, 1998, 19(4), 657-675.
- [5] McGwire K., Minor T., Fenstermaker L. *Remote Sensing of Environment*, 1999, 72(3), 360-374.
- [6] Curran P.J. *Progress in Physical Geography*, 1994, 18(2), 247-266.
- [7] Janetos A.C., Justice C.O. *International Journal of Remote Sensing*, 2000, 21(6), 1491-1512.
- [8] Penuelas J., Filella I., Lloret P. et al. *International Journal of Remote Sensing*, 1995, 16(14), 2727-2733.
- [9] Blackburn G.A., Steele C.M. *Remote Sensing of Environment*, 1999, 70(3), 278-292.
- [10] Thenkabail P.S. *International Journal of Remote Sensing*, 2003, 24(14), 839-877.
- [11] Lyon J.G., Yuan D., Lunetta R.S., Elvidge C.D. *Photogrammetric Engineering and Remote Sensing*, 1998, 64, 143-150.

[12] Gao J. *International Journal of Remote Sensing*, 1999, 20(14), 2823-2833.

[13] Thenkabail P.S., Hall J., Lin T. et al. *International Journal of Applied Earth Observation and Geoinformation*, 2003, 4(3), 255-270.

[14] Местецкий Л.М. *Математические методы распознавания образов: курс лекций*. М.: Изд-во МГУ, 2002. 85 с. [Mestetskii L.M. *Mathematical methods of pattern recognition*, Moscow State University, 2002. 85 p.]