

---

## ИСПОЛЬЗОВАНИЕ КОСМИЧЕСКОЙ ИНФОРМАЦИИ О ЗЕМЛЕ

---

### ИССЛЕДОВАНИЕ ЛЕСНЫХ И ТОРФЯНЫХ ПОЖАРОВ ПО ДАННЫМ ГИПЕРСПЕКТРАЛЬНОГО АЭРОЗОНДИРОВАНИЯ

© 2011 г. В. В. Козодеров\*, Т. В. Кондранин, Е. В. Дмитриев, В. П. Каменцев

*Московский государственный университет им. М.В.Ломоносова, Москва*

*\*E-mail: vkozod@mes.msu.ru*

Поступила в редакцию 02.03.2011 г.

Рассматриваются особенности аэрокосмической гиперспектрометрии при реализации методов классификации соответствующих изображений. Приводится описание существующих подходов к построению классификаторов (вычислительных процедур) для распознавания природно-техногенных объектов на гиперспектральных изображениях. Обосновывается эффективность разрабатываемых методов при уменьшении размерности признакового пространства исходных спектров и уменьшении объема обучающих выборок для выбранных классов объектов. По данным совмещенной гиперспектральной и аэрофотосъемки демонстрируются примеры спектрального хода дымов разной степени интенсивности от лесных и торфяных пожаров при наличии очагов возгорания и их отсутствии, задымления водных поверхностей, для лесной растительности, не тронутой пожарами на выбранной территории. Полученные примеры обучения классификаторов используются для распознавания иллюстрируемых сцен аэрозондирования в период летних пожаров на тестовой территории.

**Ключевые слова:** гиперспектральные аэрокосмические изображения, распознавание природно-техногенных объектов, вычислительные процедуры, лесные и торфяные пожары

#### ВВЕДЕНИЕ

С повышением разрешающей способности космических снимков, увеличением геометрической точности привязки и появлением составных ортофотомозаик данные дистанционного зондирования Земли (ДЗЗ) из космоса начинают играть инфраструктурную роль. Примером служат проекты Google Earth и др., доступность которых в сети Интернет способствует замещению традиционных картографических материалов данными космической съемки. Этот сегмент рынка все активнее осваивается компаниями с частным капиталом, поскольку создается высокоинтеллектуальный информационный продукт коммерческого использования. Инфраструктура пространственных данных (ИПД) как составная часть “электронного правительства” в кадастровых, геоинформационных и других системах имеет непосредственное отношение к оказанию услуг в сфере земельно-имущественных отношений, строительства, где велика роль бизнеса (Пространственные данные ..., 2010). При этом пакеты прикладных программ обработки данных гиперспектрального и многоспектрального зондирования (ERDAS, ENVI и др.), поставляемые зарубежными фирмами, содержат лишь некоторые стандартные процедуры классификации объектов по их аэрокосмическим изображениям.

Жесткая конкуренция разработчиков космических систем сверхвысокого пространственного

разрешения (менее 1 м, но с малым числом спектральных каналов) приводит к особой востребованности информационной продукции обработки данных именно такого разрешения со стороны пользователей для целей ИПД. Возможности космических систем гиперспектрального зондирования (Huregion и др.) до конца не ясны, как и создание вычислительных сред для развития возникающих новых приложений. Традиционные приложения развиваются в форме создания географических информационных систем (ГИС), интегрирующих базы данных различного назначения. В России основной акцент в ГИС сделан на среду ESRI (Environmental Systems Research Institute) – название дано американской компанией, которая существует на мировом рынке уже около 40 лет. Программная составляющая в этой среде невелика по сравнению с вкладом специалистов в области географии, геодезии, картографии и смежных наук. В то же время хорошо известна среда MATLAB, в которой сосредоточены основные приложения методов вычислительной математики. При обработке данных гиперспектрального зондирования, когда требуется оптимизация числа спектральных каналов в заданной предметной области, возрастает роль этой среды как связующего звена между традиционными подходами и новыми приложениями (Козодеров и др., 2010).

Приложения методов аэрокосмической гиперспектрометрии основаны на использовании следующих вычислительных процедур: выбор спектров объектов для обучения; рассмотрение признакового пространства исходных данных дистанционного зондирования; построение классификаторов для распознавания объектов. В данной публикации приводится краткий обзор построения классификаторов для распознавания природно-техногенных объектов по их гиперспектральным изображениям, рассматривается постановка задачи обучения по тестовой выборке, приводятся примеры спектров разных объектов. В развитие начального этапа исследований (Дмитриев и др., 2010) здесь основной акцент сделан на сравнении спектров районов, охваченных лесными и торфяными пожарами летом 2010 г. и не охваченных пожарами на тестовой территории Тверской обл.

### КРАТКИЙ ОБЗОР СУЩЕСТВУЮЩИХ МЕТОДОВ КЛАССИФИКАЦИИ ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ

Одной из первой систем гиперспектрального аэрозондирования была аппаратура “Самолетный гиперспектрометр видимой и ближней инфракрасной области” (Airborne Visible Infra-Red Imaging Spectrometer/AVIRIS) (Green et al., 1998) со спектральным разрешением около 10 нм в области длин волн от 0.4 до 2.5 мкм. Обработка данных гиперспектрального зондирования приводит к усложнению математического формализма распознавания образов соответствующих объектов в сравнении с обработкой данных многоспектрального зондирования. Возникают специфические задачи классификации объектов и анализа спектральной смеси данных для объектов, попадающих в поле зрения аппаратуры. Большинство существующих приложений данных гиперспектрального зондирования основано на анализе спектральных, а не пространственных свойств обрабатываемых данных (Hsieh, Landgrebe, 1998).

Проблема обработки данных гиперспектрального аэрокосмического зондирования содержит два аспекта: требуется обрабатывать данные очень большого объема, хотя пространственная корреляция для соседних пикселей может быть очень высокой; высокое пространственное разрешение, которое может содержать тонкие детали интерпретации конкретной сцены, в некоторых приложениях может не улучшать результаты интерпретации такой сцены. Вследствие стремления к использованию малого объема обучающих выборок и большого числа характерных признаков в регистрируемых спектральных образах объектов возникают трудности надежной оценки параметров состояния этих объектов при их статистической классификации по данным гиперспектрального зондирования (Foody, Mathur, 2004). В результате

при ограниченной обучающей выборке точность классификации уменьшается, хотя число признаков (регистрируемого разнообразия кривых спектрального хода) возрастает.

Один из путей учета многомерности признакового пространства гиперспектральных данных – рассмотрение геометрических свойств разделения классов вместо их статистических свойств. Метод опорных векторов (Support Vector Machine/SVM) (Bruzzone et al., 2006) – пример преимуществ неполного обучения в сочетании с контекстуальной информацией. В методе опорных векторов акцент делается на изучение локальных вариаций спектральной энергии путем введения семейства пространственно инвариантных функций, называемых ядрами, для реализации соответствующего процесса обучения классификатора (Plaza et al., 2009). Исходный бинарный классификатор этого метода позволяет построить оптимальную гиперплоскость, которая для заданной обучающей последовательности максимизирует границу между классами при минимизации суммы ошибок классификации (Scholkopf et al., 1998). Решается так называемая проблема выпуклой оптимизации.

Введение понятия спрямляющего пространства позволяет использовать идеологию SVM для построения нелинейного классификатора. При этом производится преобразование скалярного произведения введением тех или иных ядерных функций. В качестве последних наиболее часто используются полиномиальные или гауссовские. Если есть априорная информация, позволяющая сделать удачное предположение относительно вида разделяющей поверхности, то ее учет в ядерной функции данного метода позволяет улучшить результаты классификации либо хотя бы сократить расчетное время.

Возможно расширение бинарного классификатора метода SVM на случай большого числа классов. При этом используются классические стратегии “один против одного” и “один против остальных”. Отличительная черта метода – достижение очень высокой точности классификации (порядка 90% и выше при построении полной матрицы ошибок) для любой из используемых ядерных функций, даже если число обучающих пикселей составляет всего несколько десятков. Достигаются такие высокие показатели за счет того, что при реализации классификатора контролируется попиксельная энергия спектров в соответствии с используемой нормой выделения границ между классами.

Стандартный подход рассматриваемых ядерных методов – декомпозиция проблемы множества классов на проблему пар классов (Hsu, Lin, 2002). Тогда стандартные SVM-классификаторы могут быть реализованы в параллельных расчет-

ных схемах. Но обычно число обучающих векторов в каждой паре классов неодинаково, что приводит к тому, что процессоры, для которых используется большое число обучающих векторов, будут отставать от остальных процессоров. Получается, что один из процессоров становится “хозяином” (master), а остальные – “рабами” (slaves, workers), с точки зрения реализации алгоритма параллельных вычислений на многопроцессорных компьютерах. В реальности ускорение расчетных процедур за счет использования нескольких процессоров по сравнению с одним из них не бесконечно и носит нелинейный характер, достигая при определенном их числе оптимальной производительности.

Достижения в производительности компьютеров кластерного типа или распределенных сетей (grids) с созданием специализированных программных модулей характеризуют реально высокий потенциал обработки данных гиперспектрального зондирования с акцентом на параллельные вычисления. Распознавание образов (pattern recognition) – обширная область прикладной математики, в которой исследуются особенности компьютерных систем выделять характерные признаки (features) объектов на окружающем их фоне (background) и принимать решения по возможной классификации образов этих объектов на основе сравнения выделенных признаков и текущих измерений состояния объектов. Типичными являются две разные процедуры распознавания образов объектов по данным ДЗ: классификация с обучением (supervised classification); классификация без обучения (unsupervised classification), т.е. использование свойства кластеризации объектов в пространстве признаков. Любая конструкция системы распознавания образов содержит следующие элементы: усвоение и предварительная обработка данных; принятие решений о принадлежности текущих элементов распознающей системы к тем или иным классам объектов. Любая система распознавания функционирует тем самым в двух модах: обучение (training) и классификация (testing). Терминология распознавания включает также: “обучение с учителем” (supervised learning) – с использованием помеченных выборочных данных (labeled training samples); “обучение без учителя” (unsupervised learning) – без помеченных выборочных данных (unlabeled training samples). Модель принятия решений обычно строится таким образом, чтобы добиться малых внутриклассовых вариаций и больших межклассовых вариаций (Jain et al., 2000).

Принципы статистического распознавания образов основаны на том, что каждый образ объекта отображается как вектор в признаковом пространстве. Задача состоит в том, чтобы добиться компактного размещения векторов в признаковом пространстве, принадлежащих разным клас-

сам. Эффективность алгоритма распознавания определяется тем, как разделяются эти классы. Имея набор обучающих образов для каждого класса, решается задача разделения границ между разными образами в признаковом пространстве. Задача разделения классов (дискриминантного анализа) формулируется как задача принятия решения на основе линейных или квадратичных функций и далее нахождения “наилучшей” разделяющей границы (используя, например, критерий среднеквадратичной ошибки) на основе обучающих образов. Нейронные сети рассматриваются как модели параллельных компьютерных систем с большим числом процессоров и взаимных связей, а также с некоторыми принципами организации (способность к обучению, адаптивность, т.е. возможность приспособления к новым связям, генерализация, т.е. возможность расширения отдельных результатов для общих случаев). Указанные модели применимы для нахождения самых общих связей, в том числе нелинейных, между входными и выходными данными в процедурах распознавания образов.

Возвращаясь к необходимости соответствия исходных (training) и тестовых (testing) наборов данных, следует иметь в виду, что чем меньше первый из этих наборов, тем меньшим обобщением (генерализацией) обладает классификатор. В этом случае говорят о его невысокой “робастности”. С другой стороны, если мал тестовый набор данных, то низкой оказывается статистическая значимость (уровень доверия) полученных результатов. Если же рассматривать процедуры “классификации без учителя”, то задача построения классификатора для обработки данных гиперспектрального зондирования сводится к нахождению свойств группирования (кластеризации) образов объектов в многомерном признаковом пространстве. Задача кластерного анализа в реальности очень сложна: образы в пределах определенной группы (кластера) должны обладать какими-то более сходными свойствами, чем образы, принадлежащие разным кластерам; каждый кластер должен иметь большее сгущение точек, чем в областях между этими кластерами. Наиболее часто используемые алгоритмы “*K*-средних” (разбиения области сгущения точек на *K*-кластеров на основе минимизации среднеквадратических отклонений) (Benz et al., 2004) не могут объяснить условия начального и последующих разбиений на кластеры, критерий остановки соответствующих разбиений.

В работе (Dalponte et al., 2009) показаны особенности использования данных гиперспектрального зондирования для классификации лесной территории с точностью около 90%. Аналогичная точность достигнута в работе (Clark et al., 2005) при изучении тропической растительности по данным гиперспектральной аппаратуры HYDICE с использованием трех разных классификаторов. В

исследованиях подобного типа используются вычислительные процедуры полного анализа матрицы ошибок, включая ошибку “ложной тревоги” и “пропуска цели” (Козодеров, Дмитриев, 2010). Стоит задача обоснования оптимального набора спектральных каналов, обеспечивающих решение конкретной прикладной задачи с определенной точностью.

Из представленных материалов обзора следуют два основных вывода, касающихся повышения эффективности распознавания гиперспектральных изображений: возможность уменьшения размерности признакового пространства; возможность минимизации числа обучающих пикселей для выбранных классов объектов. Первая из указанных возможностей реализуется на основе вычислительных процедур дискриминантного анализа (Bandos et al., 2009). Метод опорных векторов (Vapnik, Chapelle, 2000) способствует реализации второго подхода.

#### ПОСТАНОВКА ЗАДАЧИ РАСПОЗНАВАНИЯ ОБЪЕКТОВ С ОБУЧЕНИЕМ ПО ТЕСТОВОЙ ВЫБОРКЕ

Каждый спектр гиперспектрального зондирования отображается в виде вектора в многомерном признаковом пространстве с размерностью, равной числу каналов, а множество текущих спектров отображается в виде отдельных точек кластеризации в этом пространстве. В процедурах распознавания двух классов объектов линейный дискриминантный анализ составляет поиск оптимальной в смысле байесовского подхода разделяющей плоскости между двумя множествами точек. Задача построения классификатора в этом случае сводится к линейному преобразованию  $\mathbf{G}$ , которое проектирует выборку из векторов  $\mathbf{x}$  исходного признакового пространства в пространство меньшей размерности. В иллюстрируемых ниже примерах размерность вектора  $\mathbf{x}$  соответствует числу используемых спектральных каналов (до 232). Указанное преобразование можно представить как

$$\mathbf{u} = \mathbf{G}^T \mathbf{x},$$

где  $\mathbf{x}$  – вектор размерности  $n$ ,  $\mathbf{u}$  – вектор отображения, имеющий размерность  $m < n$ ,  $\mathbf{G}$  – матрица размерности  $m \times n$ ,  $T$  – знак транспонирования матрицы. Строками матрицы  $\mathbf{G}^T$  служат  $m$  выбранных векторов-признаков, т.е. коэффициентов линейной связи исходных спектров и их отображения в признаковом пространстве. Здесь и далее векторы описания спектров в пространстве признаков обозначаются как  $\mathbf{x} = (x^1, \dots, x^n)$ , а векторы описания элементов обучающих выборок как  $x_i$  (также и для других рассматриваемых ниже

векторов), хотя для этих величин предполагается, что  $\mathbf{x}_i = (x_i^1, \dots, x_i^n)$ .

Задача отыскания матрицы преобразования в случае общего числа  $L$  классов состоит в том, чтобы выбрать направление  $\mathbf{d}$  в признаковом пространстве, вдоль которого расстояния средних векторов для каждого класса было максимальным, а вариации вокруг этих средних были минимальными, что соответствует критерию нахождения следующего максимума:

$$\text{Arg max}_{\mathbf{d}} (\mathbf{d}^T \mathbf{S}_b \mathbf{d} / \mathbf{d}^T \mathbf{S}_w \mathbf{d}),$$

где в соответствии с общей матрицей рассеяния  $\mathbf{S} = \mathbf{S}_b + \mathbf{S}_w$ , которая служит оценкой общей ковариационной матрицы гиперспектральных данных, введены обозначения:

– межклассовая вариация исходных векторов для каждой из групп классов ( $n_i$ )

$$\mathbf{S}_b = n^{-1} \sum_{i=1}^L n_i (\mu_i - \mu)(\mu_i - \mu)^T,$$

– внутриклассовая вариация

$$\mathbf{S}_w = n^{-1} \sum_{j=1}^L \sum_{i \in U_j} n_i (x_i - \mu_j)(x_i - \mu_j)^T,$$

где  $\mu_i$  – выборочные средние значения,  $U_j$  означает индексный набор признаков, принадлежащих классу  $j$ .

При предположениях нормального распределения образов  $i$ -го класса и равенства всех ковариационных матриц  $\mathbf{C}_1 = \mathbf{C}_2 = \dots = \mathbf{C}_M = \mathbf{C}$  для исходных спектров математическое ожидание ( $\mu_i^*$ ) их отображения  $\mathbf{u}$  можно записать как

$$\mu_i^* = \mathbf{G}^T \mu_i,$$

что позволяет представить ковариационную матрицу такого отображения в виде

$$\mathbf{V} = E \left\{ \left( \mathbf{u} - \mu_i^* \right) \left( \mathbf{u} - \mu_i^* \right)^T \right\} = \mathbf{G}^T E \{ \mathbf{z} \mathbf{z}^T \} \mathbf{G} = \mathbf{G}^T \mathbf{C} \mathbf{G},$$

так как  $E \{ \mathbf{z} \mathbf{z}^T \} = \mathbf{C}$  для  $\mathbf{z} = \mathbf{x} - \mu_i$  ( $E$  – символ математического ожидания).

В реальности для полученных квадратных матриц размерности  $m \times m$  требуется найти отклонение математического ожидания среднего квадрата общей матрицы  $\mathbf{Q}$  рассеяния спектров относительно квадрата среднего значения этой матрицы, что необходимо для решения задачи оптимальной делимости классов объектов по их спектральным признакам. Это отклонение определяется следом (trace) произведения ука-

занной матрицы  $\mathbf{Q}$  и матрицы  $\mathbf{V} = \mathbf{V}(\mathbf{u})$  дисперсий-ковариаций элементов вектора  $\mathbf{u}$  (Дрейпер, Смит, 1986):

$$\text{trace}(\mathbf{QV}) = E(\mathbf{V}^T \mathbf{QV}) - E\mathbf{V}^T \mathbf{Q} E\mathbf{V}.$$

След любой матрицы по определению равен сумме ее диагональных элементов. В нашем случае фигурирует квадратичная форма  $\mathbf{V} = \mathbf{G}^T \mathbf{S}_b \mathbf{G}$  для матрицы межклассового рассеяния спектров и аналогичная ей форма  $\mathbf{Q} = (\mathbf{G}^T \mathbf{S} \mathbf{G})^{-1}$  для обратной матрицы общего рассеяния спектров. Таким образом, окончательно записанный выше критерий разделимости классов можно записать в виде

$$\mathbf{G}^* = \text{Arg max}_{\mathbf{G}} \left\{ \text{trace}(\mathbf{G}^T \mathbf{S} \mathbf{G})^{-1} \mathbf{G}^T \mathbf{S}_b \mathbf{G} \right\}.$$

Полученное решение задачи классификации объектов в признаковом пространстве уменьшенной размерности (в сравнении с исходным многомерным пространством, равным числу каналов гиперспектрального зондирования) может быть упрощено, если разложить матрицу  $\mathbf{S}^{-1} \mathbf{S}_b$  по собственным векторам и выбрать главные компоненты изменчивости спектров.

В процедурах квадратичного дискриминантного анализа, получаемых на основе байесовского подхода, сохраняются основные возможности понижения размерности признакового пространства с отмеченными здесь следствиями нахождения оптимальных критериев разделимости классов. При построении классификатора делается предположение, что внутри каждого класса  $i$  (для каждого объекта) признаки имеют многомерное нормальное распределение  $D_i = N(m_i, S_i)$ , где  $m_i$  и  $S_i$  соответственно математические ожидания и матрицы ковариаций каждого класса. Наиболее вероятный класс  $i_{opt}$  определяется как

$$i_{opt} = \text{arg max}_i \left( \ln(P(x \sim D_i)) - \frac{1}{2}(x - m_i)^T \times \right. \\ \left. \times S_i^{-1}(x - m_i) - \frac{1}{2} \ln(\det(S_i)) \right).$$

Если ковариационные матрицы разных классов отличны друг от друга, то соответствующие разделяющие поверхности представляются полиномами второго порядка.

Дальнейшее повышение эффективности вычислительных процедур распознавания объектов на гиперспектральных изображениях связано с возможностью уменьшения длины обучающей выборки для каждого класса без ущерба для точности распознавания. При бинарной классификации задано пространство исходных спектров в виде векторов  $\mathbf{x}$  и множества предварительных ответов о разделении классов  $\mathbf{y}$  (например,  $-1$  и  $+1$ ). Для обучающей выборки задана целевая функция разби-

ения на классы, а требуется построить алгоритм, аппроксимирующий целевую функцию на всем пространстве обрабатываемых гиперспектральных данных. Для весовых векторов  $\mathbf{w}$ , линейно связывающих векторы  $\mathbf{x}$  и  $\mathbf{y}$ , и свободного члена  $b$ , характеризующего пересечение разделяющей плоскости с координатными осями, можно одновременно максимизировать зазор (margin) (минимизируется норма вектора  $\mathbf{w}$ ) и минимизировать суммы ошибок всех  $\xi_i$  объектов-нарушителей. Это те объекты, которые в процессе обработки данных могут попадать на другую сторону разделяющей гиперплоскости. При нелинейном отображении  $\Phi(\mathbf{x})$  решающее правило соответствует разделению классов по знаку

$$\text{sign}[a(\mathbf{x})],$$

где  $a(\mathbf{x}) = \langle \mathbf{w}, \Phi(\mathbf{x}) \rangle + b$ ,

$\langle \dots \rangle$  – символ скалярного произведения векторов.

В методе опорных векторов на объектах обучающей выборки  $\mathbf{x}_i$ ,  $i = 1, \dots, J$  решается оптимизационная задача (Dalponte et al., 2009):

$$1/2 \langle \mathbf{w}, \mathbf{w} \rangle + C \sum_i \xi_i \rightarrow \min | \mathbf{w}, b, \xi; \\ y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle - b) \geq 1 - \xi_i, \xi_i \geq 0;$$

$C \geq 0$  – управляющий параметр регуляризации решения.

Построение оптимальной разделяющей гиперплоскости для общего случая линейно неразделимой выборки сводится к следующей задаче нелинейного программирования. Для всех векторов  $\mathbf{x}_i$  обучающей выборки задача сводится к минимизации квадратичной формы при следующих ограничениях-неравенствах (их общее число равно длине выборки):

$$\langle \mathbf{w}, \mathbf{x}_i \rangle + b \leq -1, \quad \text{если } y_i = -1; \\ \langle \mathbf{w}, \mathbf{x}_i \rangle + b \geq 1, \quad \text{если } y_i = +1.$$

В рассматриваемой постановке задача эквивалентна двойственной задаче поиска седловой точки функции Лагранжа:

$$L(\mathbf{w}, b, \xi, \alpha, \eta) = 1/2 \langle \mathbf{w}, \mathbf{w} \rangle - \\ - \sum_i \alpha_i (y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1) - \sum_i \xi_i (\alpha_i + \eta_i - C),$$

где с учетом сделанных выше замечаний относительно векторов обучающих выборок предполагается:  $\alpha_i = (\alpha_1, \dots, \alpha_J)$  – вектор двойственных переменных решаемой минимаксной задачи (min по  $\mathbf{w}$  и  $b$ ; max – по  $\alpha$ ),  $\eta_i = (\eta_1, \dots, \eta_J)$  – вектор переменных, двойственных по отношению к переменным  $\alpha_i$ .

Учитывая то обстоятельство, что необходимое условие седловой точки – равенство нулю производных функции Лагранжа, можно получить яв-

ное выражение для вектора  $w$  и свободного члена  $b$ , а также соответствующие условия связи введенных векторов

$$\begin{aligned} \partial L / \partial w = w - \sum_i \alpha_i y_i x_i = 0 \rightarrow w = \sum_i \alpha_i y_i x_i, \\ b = y_i - \langle w, x_i \rangle; \end{aligned}$$

$$\partial L / \partial b = -\sum_i \alpha_i y_i = 0 \rightarrow \sum_i \alpha_i y_i = 0;$$

$$\partial L / \partial \xi_i = -\alpha_i - \eta_i + C = 0 \rightarrow \alpha_i + \eta_i = C.$$

Все объекты обучающей выборки  $x_i$  называются опорными векторами (support vector), если  $\alpha_i > 0$  и  $y_i = \langle w, x_i \rangle + b$ . Соответственно при так называемом отступе (margin)  $m_i = y_i - (\langle w, x_i \rangle + b)$  объектов  $x_i$  от границы классов все объекты делятся на три типа:

$\alpha_i = 0; \eta_i = C; \xi_i = 0; m_i > 1$ . Объект  $x_i$  классифицируется правильно и находится далеко от разделяющей полосы. Это периферийные объекты;

$0 < \alpha_i < C; 0 < \eta_i < C; \xi_i = 0; m_i = 1$ . Объект  $x_i$  классифицируется правильно и лежит в точности на границе разделяющей полосы. Это опорные объекты;

$\alpha_i = C; \eta_i = 0; \xi_i > 0; m_i < 1$ . Объект  $x_i$  либо лежит внутри разделяющей полосы, но классифицируется правильно ( $0 < \xi_i < 1; 0 < m_i < 1$ ), либо попадает на границу класса ( $\xi_i = 1; m_i = 0$ ), либо относится к чужому классу ( $\xi_i > 1; m_i < 0$ ). Это объекты-нарушители.

Итог рассмотренных вычислительных процедур: для быстрого нахождения всех векторов-коэффициентов  $w$  решается задача выпуклой оптимизации, имеющая единственное решение

$$\begin{aligned} \max_{\alpha} \left\{ \sum_i \alpha_i - 1/2 \sum_{i,j} \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle \right\}; \\ 0 < \alpha_i < C; \quad \sum_i \alpha_i y_i = 0. \end{aligned}$$

Нелинейность вводится с помощью так называемых ядерных функций

$$K(x_i, x_j) = \langle \Phi(x_i) \Phi(x_j) \rangle,$$

что при отображении  $\Phi: X \rightarrow H$  расширяет пространство ( $X$ ) входных векторов на пространство ( $H$ ). Следствие – сведение задачи бинарной классификации к задаче квадратичного программирования, имеющей единственное решение, относительно двойственных переменных  $\alpha_i$ :

$$\begin{aligned} \max_{\alpha} \left\{ \sum_i \alpha_i - 1/2 \sum_{i,j} \alpha_i \alpha_j y_i y_j \langle \Phi(x_i), \Phi(x_j) \rangle \right\}; \\ 0 < \alpha_i < C; \quad \sum_i \alpha_i y_i = 0. \end{aligned}$$

Если перенумеровать объекты так, чтобы первые  $h$  объектов оказались опорными, то поскольку  $\alpha_i = 0$  для всех неопорных объектов,  $i = h + 1, \dots, J$ , при решающем правиле  $\text{sign}[a(x)]$  дискриминантная функция определяется суммированием следующего выражения только по опорным векторам используемой выборки ( $i = 1, \dots, h$ ):

$$a(x) = \sum_i \alpha_i y_i K(x_i, x) + b,$$

где ядерная функция должна быть симметричной  $K(x_i, x_j) = K(x_j, x_i)$  и неотрицательно определенной

$$\iint_{X \times X} K(x, x') g(x) g(x') dx dx' \geq 0$$

для любой функции  $g$ .

При этом следует иметь в виду, что этому соотношению удовлетворяют лишь некоторые из известных функций: полиномиальная, гауссовская и некоторые другие.

Переход от бинарной классификации к проблеме многих классов реализуется в соответствии с двумя возможными стратегиями:

– “каждый против каждого” – решается  $L(L - 1)/2$  бинарных проблем распознавания пары классов и неким “голосованием” определенным класс получает большинство из ансамбля бинарных классификаторов;

– “один против всех”, когда используется правило “победитель забирает все”, т.е. принимается решение, что ценность соответствующей дискриминантной функции наивысшая.

Ниже иллюстрируются приложения перечисленных вычислительных процедур классификации объектов на гиперспектральных изображениях с обучением по тестовой выборке.

### ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

На рис. 1 (см. на цветн. вклейках) приведен пример совмещенной аэрофотосъемки (а) и гиперспектральной (б) съемки выбранной территории, охваченной и не охваченной лесными и торфяными пожарами на дату съемки 31.07.2010 г. На рис. 1б приведено RGB-синтезированное по исходным 232 каналам изображение гиперспектрометра размерностью  $8262 \times 500$  пикселей. Такое синтезирование позволяют отобразить гиперспектральные данные аэрозондирования в виде пространственного распределения пикселей, близкого к естественным цветам.

Изображение рис. 1б охватывает большую часть исходных кадров аэрофотосъемки (рис. 1а). Слева направо на изображениях рис. 1 можно видеть объекты: дым над торфоразработками, дым над системой озер, отдельные очаги лесных пожаров, разные типы растительности (зеленого и жел-

того цвета) при отсутствии пожаров. На рис. 1а показаны: области закончившегося пожара, но с разной степенью обгорания и текущего задымления (1), фронт интенсивного горения (2), области изменения интенсивности шлейфа дыма (3), дым над поверхностью озер (4), область верхового лесного пожара (5). Видны также лесные массивы вблизи очагов горения (6) и массивы, не тронутые пожарами (7).

Иллюстрируемые ниже примеры демонстрируют исходные спектры в Вт/(см<sup>2</sup> мкм стер) в пределах выделенных контуров на изображениях рис. 1 вместе со стандартными отклонениями этих спектров, а также соответствующие им спектры в нм<sup>-1</sup>, нормированные на интегральную яркость, и их стандартные отклонения. Процедура нормирования спектров необходима для уменьшения влияния внешних факторов съемки (разные условия солнечного освещения, замутнения атмосферы и др.) при распознавании объектов по данным их гиперспектрального зондирования для разных сцен.

Цифры на изображениях рис. 2а–2г (на цветн. вклейках) и на последующих иллюстрациях соответствуют строкам и столбцам исходной матрицы рис. 1б. Пример рис. 2а характеризует самую правую область задымления над лесной растительностью от очага пожара, который можно наблюдать в нижней части рис. 1. Данные рис. 2б и рис. 2в относятся к области другого наблюдаемого очага пожара над лесной растительностью с сильным задымлением (б) и слабым задымлением (в). Данные рис. 2г характеризуют задымление растительности над полянами торфяных разработок (слева на рис. 1б), где видна типичная прямоугольная структура торфоразработок.

На рис. 2д (на цветн. вклейках) показаны спектры и их стандартные отклонения, характеризующие два указанных контура сильного задымления растительности (рис. 2а и рис. 2б), а также ее среднего (рис. 2в) и слабого задымления (рис. 2г). Данные рис. 2е (на цветн. вклейках) относятся к нормированным спектрам и их стандартным отклонениям.

Из данных рис. 2д можно сделать выводы, что типичное проявление сильного задымления — характерный максимум спектров в коротковолновой области (480–550 нм). Другой максимум замечен в области (750–800 нм) с минимумом между этими крайними длинами волн, обусловленным полосой поглощения кислорода (762 нм) в атмосфере. Можно видеть также наличие других полос поглощения во всей области (400–800 нм), а также воздействие полос поглощения водяного пара для длин волн более 800 нм. Если в коротковолновой области кривые рис. 2д пересекаются, то в области другого указанного максимума значения амплитуд спектров для двух выбранных контуров сильного задымления различаются. Различия касаются того,

что кривые красного цвета на рис. 2д характеризуют область, когда очаг горения с высокой температурой среды (пламя от пожара) находится на более близком расстоянии к выбранному контуру, чем в случае кривых зеленого цвета, когда такой очаг удален от оконтуренной области. По мере уменьшения атмосферного задымления зарегистрированные спектры становятся все более похожими на типичные спектры растительности (кривые черного цвета в сравнении с кривыми синего цвета на рис. 2д) с явным проявлением характерного минимума в полосе поглощения хлорофилла (вблизи 670 нм).

Кривые рис. 2е для нормированных спектров отличаются от аналогичных кривых рис. 2д для исходных спектров. Отличия можно заметить в том, что в области 400–700 нм амплитудные значения спектров для разных условий задымления сближаются между собой для разных длин волн. При этом кривые черного цвета (слабое задымление) на рис. 2е продолжают иметь самые низкие значения зарегистрированных яркостей, а кривые синего цвета (среднее задымление) по амплитуде даже превышают кривые красного цвета (сильное задымление). В области 750–800 нм амплитуда нормированных спектров максимальна при слабом задымлении (кривые черного цвета), а минимальна эта амплитуда для практически сливающихся кривых синего и зеленого цветов.

На рис. 3 (на цветн. вклейках) показаны изображения гиперспектрометра с выделенными контурами выборочных спектров, характеризующих фронт горения (а, б) самого правого очага на рис. 1 (с проглядывающей сквозь дым растительностью и при сплошной дымовой завесе, соответственно), а также открытое пламя верхового пожара (в). Выделенным контурам соответствуют исходные спектры, приведенные на рис. 3г, и нормированные спектры, приведенные на рис. 3д.

Из данных рис. 3г можно видеть, что амплитуды спектров фронта горения над растительностью (а) (кривые красного цвета) во всем диапазоне длин волн меньше соответствующих величин для дыма вблизи фронта горения (б) (кривые зеленого цвета). Здесь простое объяснение — дым становится более ярким во всем диапазоне длин волн вблизи очага горения в сравнении с дымом над растительностью от удаленного очага. В области длин волн 400–700 нм спектры для открытого очага горящего леса (кривые синего цвета) располагаются между этими кривыми, но для области 720–800 нм идут выше них. Еще более значительны амплитуды спектров в области 400–700 нм для уже рассмотренного примера контура рис. 2б очень сильного задымления над лесной растительностью (здесь этот пример представлен кривыми черного цвета, которые, как видно, фактически сливаются с кривыми синего и зеленого

цвета для длин волн более 720 нм). Из сказанного можно сделать вывод об определяющей роли именно коротковолновой области спектра при гиперспектральном отображении дымов разной интенсивности и в меньшей степени о зависимости амплитуды наблюдаемой длинноволновой моды от интенсивности пожара. Для нормированных спектров (рис. 3д) спектральные кривые все более стягиваются между собой, отображая факт их меньшей изменчивости для разных пикселей в сравнении с исходными спектрами. При этом максимальные значения в коротковолновой области имеют спектры, относящиеся к районам сильного задымления (черный цвет), минимальные — к районам открытого верхового пожара. В длинноволновой области, наоборот, горящий лес становится более ярким в сравнении с остальными объектами, особенно в случае их сильного задымления.

На рис. 3е представлены два вида уже рассмотренных спектральных кривых и их изменчивости (горящий лес, красный цвет, соответствует рис. 3в; для области сильного задымления над растительностью, зеленый цвет, соответствует рис. 2а). Видно, что кривые для горящего леса идут ниже кривых для области сильного задымления лесной растительности во всей области длин волн 400–1000 нм вопреки интуитивному предположению, что пламя горящего леса должно выглядеть более ярким, чем плотная дымовая завеса.

Примеры рис. 4 (на цветн. вклейках) демонстрируют спектральные свойства дымов разной интенсивности над водной поверхностью. Данные рис. 4а и рис. 4б относятся к большой озерной системе в центре рис. 1а, данные рис. 4в — к одному из маленьких озер, на которые дым не попал. Из сравнения данных рис. 4г можно видеть, что по мере увеличения задымления водных поверхностей увеличивается амплитуда спектров во всей области длин волн 400–900 нм. При этом в области максимума воздействия дымов (460–480 нм) амплитуда спектров при среднем задымлении возрастает почти в 3 раза при переходе от кривых синего цвета на рис. 4г к кривым красного цвета. В меньшей степени различаются между собой нормированные спектры (рис. 4д), хотя указанный максимум в коротковолновой области сохраняется и для этих кривых.

Данные рис. 4е демонстрируют исходные спектры нормально вегетирующей лесной растительности, не подверженной пожару (в правой части рис. 1). Типичный ход этих спектров для всех трех иллюстрируемых видов лесной растительности: максимум вблизи длины волны 550 нм; минимум в полосе поглощения хлорофилла (670 нм); основной максимум в области длин волн 720–800 нм с полосой поглощения кислорода (762 нм); полосы поглощения водяно-

го пара (820 нм, 940 нм). Видно, что различимость спектров этих трех видов лесной растительности в коротковолновом диапазоне длин волн незначительна, но эти спектры достаточно хорошо различаются в области 720–860 нм.

Данные рис. 5 (на цветн. вклейках) относятся к наблюдениям гарей от предшествующих пожаров при весьма малом воздействии текущих пожаров. Эти три участка гарей (а, б, в) расположены слева от второго из наблюдаемых на рис. 1 факелов интенсивных пожаров и дымовой завесы от них. Из данных рис. 5г можно видеть, что выгоревшие участки различаются по форме спектров в области длин волн от 480 нм до 1000 нм. Нормирование спектров на интегральную интенсивность (рис. 5д) приводит к тому, что спектры становятся различимы главным образом в области 480–600 нм, фактически перемешиваясь для разных участков в остальных диапазонах длин волн. Становятся более ярко выраженными, чем ранее, полосы поглощения кислорода (718 нм и 762 нм), водяного пара (820 нм, 940 нм) и др.

Интерес представляет сравнение нормированных спектров одного из участков гари и нормально вегетирующей лесной растительности вблизи очага текущего пожара и вдали от него (рис. 5е). Можно видеть существенное отличие спектрального хода участка гари (кривые красного цвета на рис. 5е) от двух других примеров спектров (кривые зеленого и синего цвета на рис. 5е). Спектр гари резко возрастает от длины волны 400 нм до 480 нм и затем плавно убывает при наличии отдельных пиков, обусловленных полосами поглощения соответствующих соединений атмосферы. Спектры растительности имеют уже упомянутые особенности: рост от длины волны 400 нм до 450 нм, незначительный минимум в области 500 нм, максимум в области 550 нм, полоса поглощения хлорофилла вблизи 670 нм, максимум в области 720–860 нм, убывание спектров для более длинных волн.

Данные рис. 2–5 можно применить в процедурах обучения классификаторов по выделенным контурам соответствующих объектов. Пример классификации гиперспектрального изображения рис. 1б по спектральным признакам показан на рис. 6а (см. рис. 6 на цветн. вклейках). Для распознавания выделенных типов природных объектов использовался квадратичный дискриминантный анализ. В процессе регуляризации решения рассматриваемой задачи проводилось объединение спектральных каналов. В случае, представленном на рис. 6а, использовалось 47 объединенных каналов с разрешением порядка 10 нм. При обучении были задействованы ансамбли выделенных эталонных спектров задымления трех градаций интенсивности над различными объектами.

Оценка степени задымления по грациям яркости осуществлялась в каналах фиолетовой области (коротковолновых каналах). Поскольку в исходных гиперспектральных данных каналы в этой области сильно зашумлены, то для уменьшения этого эффекта использовался “объединенный” канал с центральной длиной волны 414 нм и разрешением 30 нм. По этим данным были выделены наиболее заметные семь градаций яркости в диапазоне 0.023–0.11 Вт/(см<sup>2</sup> мкм стер). Качественно они соответствуют разным грациям плотности дымового шлейфа. Полученные градации степени задымления в виде черно-белых и серых градаций представлены на рис. 6б. Важно отметить, что контуры озер, лесных массивов, лугов и дорог не прослеживаются, поэтому в рамках данной сцены метод определения степени задымления по объединенным каналам фиолетовой области представляется разумным в том смысле, что полученные результаты отражают реальные градации прозрачности атмосферы.

Для облегчения восприятия распознаваемых классов на рис. 6а показаны 9 классов, полученных объединением по смысловому содержанию. Белым цветом отображено преобладание дымов сильной и средней интенсивности. На территории, которая охвачена практически сплошной дымовой завесой, выделены очаги возгорания (красный цвет). В областях слабого или почти отсутствующего задымления распознаются водные поверхности (синий цвет), гари и почвогрунты (черный цвет). Различные типы здоровой лесной растительности, не поврежденной лесными пожарами, находящиеся в правой части рис. 6а, отображены темно зеленым цветом. Редколесье и кустарники обозначены зеленым, пожелтевшая растительность обозначена желтым цветом. Растительность, находящаяся в непосредственной близости от очагов возгорания, подвергается негативному воздействию. На рис. 6а растительность различного типа, подверженная слабому и среднему воздействию пожаров при отсутствии задымления, обозначена сине-зеленым цветом, при слабом задымлении – светло-зеленым. Можно видеть характерные особенности классификации объектов (а) и уровней задымления территории (б).

Основным результатом проведенных исследований являются демонстрация особенностей спектрального хода дымов разной интенсивности, обоснование возможности автоматизации процесса обучения классификаторов по выделенным контурам объектов и реализация процедур распознавания этих объектов по данным их гиперспектрального аэрозондирования.

## ЗАКЛЮЧЕНИЕ

Аэрокосмическая гиперспектрометрия – новейшее достижение научно-технологических приложений в области использования оптических измерительных средств для решения прикладных задач. Были показаны особенности отображения лесных пожаров, других объектов природно-техногенной сферы по данным гиперспектрального зондирования и особенности разработки классификаторов (вычислительных процедур распознавания объектов) при обработке гиперспектральных изображений. Открываются перспективы создания новых программно-алгоритмических средств для распараллеливания вычислительных процессов по распознаванию образов наблюдаемых объектов.

Исследования выполняются при финансовой поддержке ФЦП “Научные и научно-педагогические кадры инновационной России” на 2009–2013 годы, г/к № П349 и № 14.740.11.1091, проектов РФФИ № 09-05-00171, 11-07-00382, 11-07-12006-офи\_м.

## СПИСОК ЛИТЕРАТУРЫ

- Дмитриев Е.В., Козодеров В.В., Кондранин Т.В.* Распознавание объектов для территорий, охваченных лесными пожарами, по данным авиационной гиперспектрометрии // Тр. МФТИ Аэрокосмические исследования, прикладная механика. 2010. Т. 2. № 3. С. 133–140.
- Дрейнер Н., Смит Г.* Прикладной регрессионный анализ. М.: Финансы и статистика, 1986. 366 с.
- Козодеров В.В., Дмитриев Е.В.* Аэрокосмическое зондирование почвенно-растительного покрова: модели, алгоритмическое и программное обеспечение, наземная валидация // Исслед. Земли из космоса. 2010. № 1. С. 69–86.
- Козодеров В.В., Кондранин Т.В., Райкунов Г.Г., Казанцев О.Ю., Белоцерковский А.В., Асташкин А.А., Бобылев В.И., Дмитриев Е.В., Каменцев В.П., Борзак В.В., Щербаков М.В., Лесуновский А.А.* Аэрокосмическая гиперспектрометрия: летные испытания аппаратуры, программно-алгоритмическое обеспечение обработки данных // Исслед. Земли из космоса. 2010. № 5. С. 59–68.
- Пространственные данные в информационных, кадастровых и геоинформационных системах. М.: ГИС-Инфо, 2010. № 2. 80 с.
- Bandos T.V., Bruzzone L., Camps-Valls G.* Classification of hyperspectral images with regularized linear discriminant analysis // IEEE Trans. Geosci. Rem. Sens. 2009. V. 47. № 3. P. 862–873.
- Benz U., Hofman P., Willhauck G., Lingenfelder I., Heynen M.* Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information // ISPRS J. Photogram. Rem. Sens. 2004. V. 58. P. 239–258.
- Bruzzone L., Chi M., Marconcini M.* A novel transductive SVM for the semisupervised classification of remote sensing images // IEEE Trans. Geosci. Rem. Sens. 2006. V. 44. P. 3363–3373.

- Clark M.L., Roberts D.A., Clark D.B.* Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales // *Rem. Sens. Env.* 2005. V. 96. P. 375–398.
- Dalponte M., Bruzzone L., Vescovo L., Gianelle D.* The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas // *Rem. Sens. Env.* 2009. V. 113. P. 2345–2355.
- Fauvel M., Gamba P., Gualtieri A., Marconcini M., Tilton J.C., Trianni G.* Recent advances in techniques for hyperspectral image processing // *Rem. Sens. Env.* 2009. V. 113. P. 110–122.
- Foody G. M., Mathur A.* Toward intelligent training of supervised image classifications: Directing training data acquisition for SVM classification // *Rem. Sens. Env.* 2004. V. 93. P. 107–117.
- Green R.O., Eastwood, M. L., Sarture, C. M., Chrien, T. G., Aronsson, M., Chippendale, B. J., et al.* Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS) // *Rem. Sens. Env.* 1998. V. 65. P. 227–248.
- Hsieh P.-F., Landgrebe D.* Lowpass filter for increasing class separability // *IEEE Trans. Geosci. Rem. Sens.* 1998. V. 36. P. 108–125.
- Hsu C.W., Lin C.J.* A comparison of methods for multiclass support vector machines // *IEEE Trans. Neural Networks.* 2002. V. 13. P. 415–425.
- Jain A.K., Duin R.P.W., Mao J.* Statistical Pattern Recognition: A Review // *IEEE Trans. pattern analysis and machine intelligence.* 2000. V. 22. № 1. P. 4–37.
- Plaza A., Benediktsson J.A., Boardman J.W., Brazile J., Bruzzone L., Camps-Valls G., Chanussot J., Fauvel M., Gamba P., Gualtieri A., Marconcini M., Tilton J.C., Trianni G.* Recent advances in techniques for hyperspectral image processing // *Rem. Sens. Env.* 2009. V. 113. P. 110–122.
- Schoolkopf B., Smola A., Muller K.R.* Nonlinear component analysis as a kernel eigenvalue problem // *Neural Computation.* 1998. V. 10. № 5. P. 1299–1319.
- Vapnik V., Chapelle O.* Bounds on error expectation for support vector machines // *Neural Computation.* 2000. V. 12. № 9. P. 2013–2036.

## Forest and Peat Fires Mapping Using Hyperspectral Airborne Remote Sensing Data

V. V. Kozoderov, T. V. Kondranin, E. V. Dmitriev, V. P. Kamentsev

*M.V. Lomonosov Moscow State University, Moscow*

Characteristic features of airspace hyperspectral remote sensing are considered to realize classification techniques for the relevant images. A description is given of the currently available approaches to construct classifiers (computational procedures) for the natural and anthropogenic objects recognition in hyperspectral images. Efficiency is accounted for the elaborated techniques while decreasing the dimensionality of the feature space and decreasing the sample volumes in supervising procedures for the selected object classes. Examples are revealed of the spectral distribution of smokes with various degree of their intensity from the forest and peat fires in the presence of fire sources and their absence, dust of fires under water bodies, for the forest vegetation that is not caused by the fires within the selected area. The obtained results of the supervising procedures are used for the pattern recognition and scene analysis in airborne images obtained for the test areas during forest fire season.

**Keywords:** hyperspectral airborne imagery, natural and anthropogenic objects recognition, computational procedures, forest and peat fires




Рис. 1. Аэрофотоснимок иллюстрируемой территории (а) и гиперспектральное изображение этой территории (б).




Рис. 6. Результаты тематической обработки гиперспектрального изображения рис.1б: классификация с использованием результатов квадратичного дискриминантного анализа (а) и градации (от черного к белому) степени задымления территории (б).



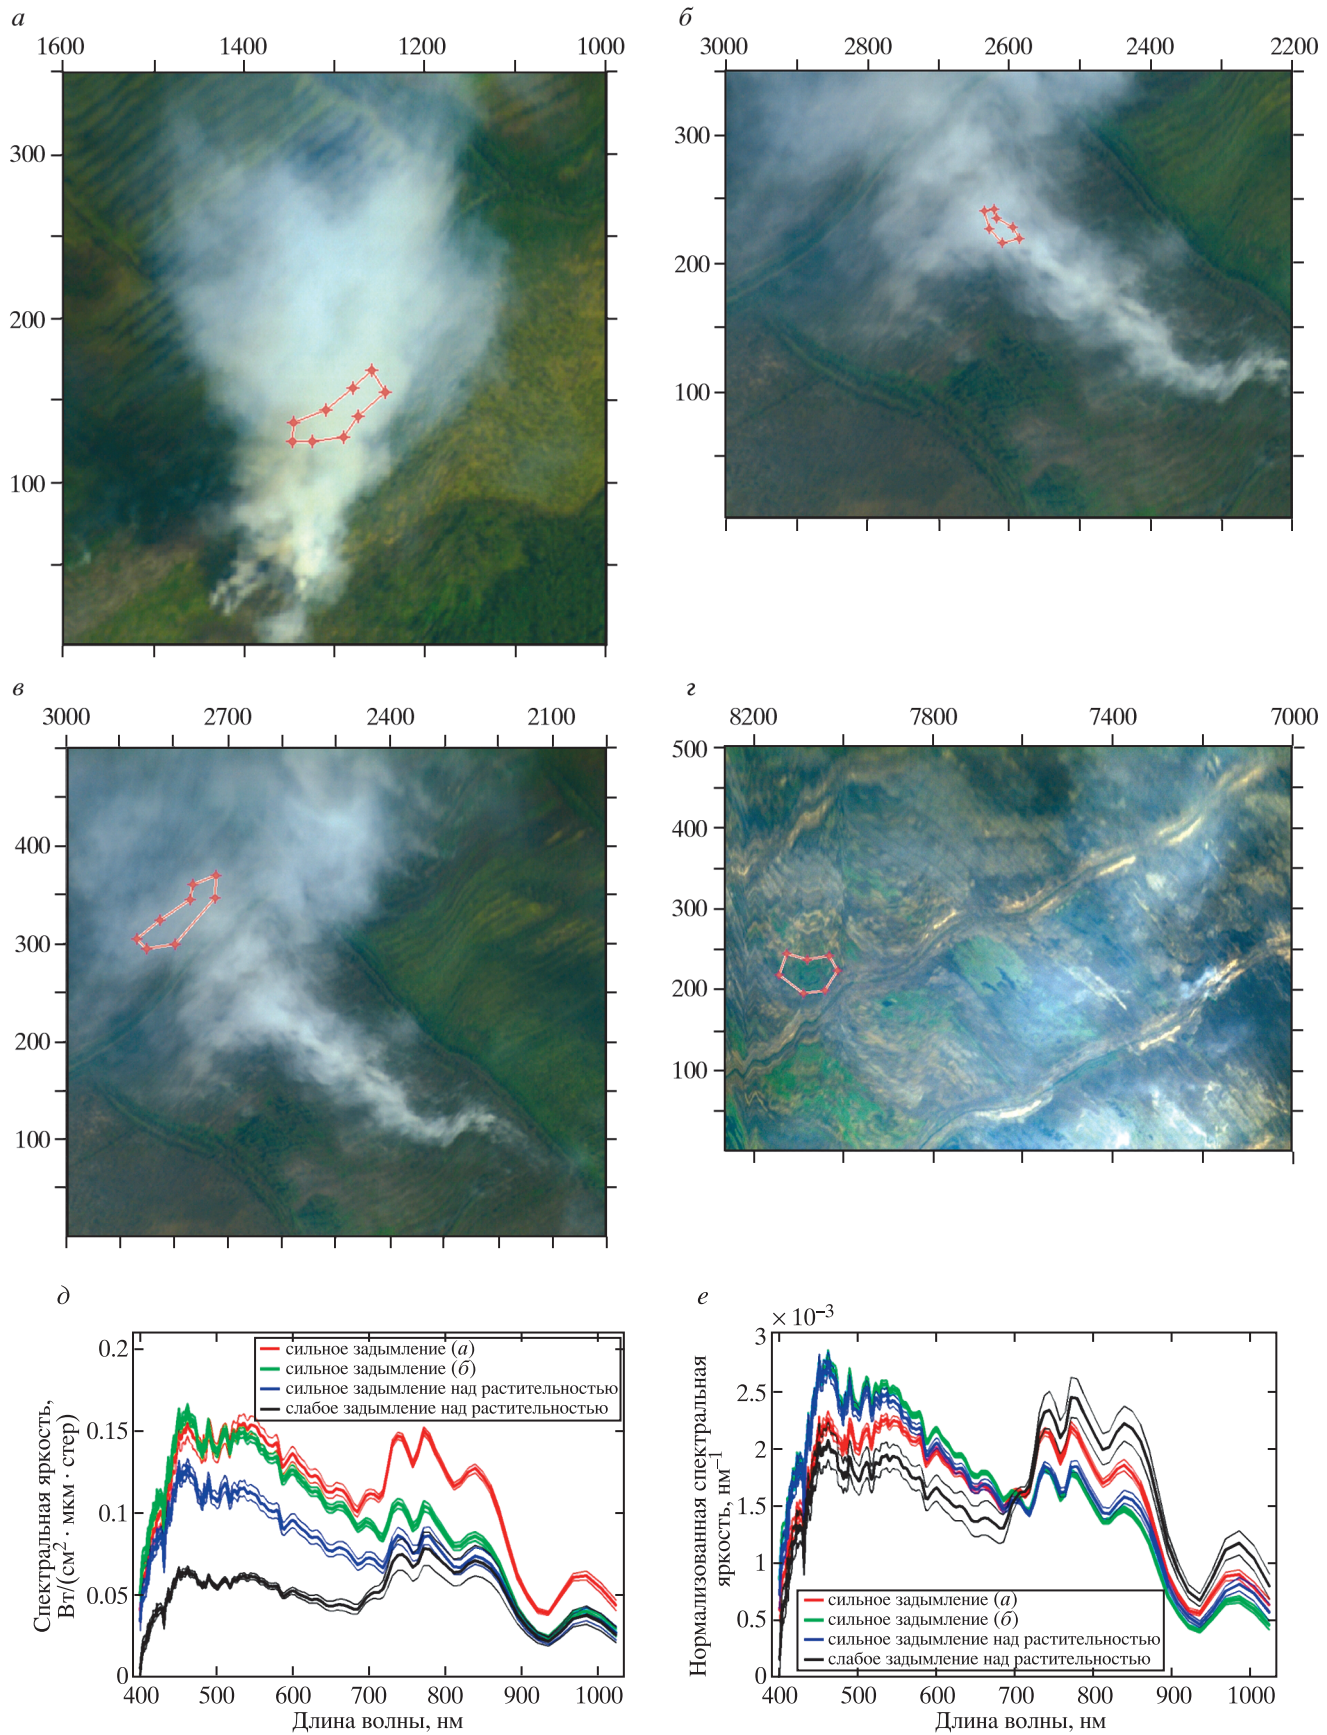
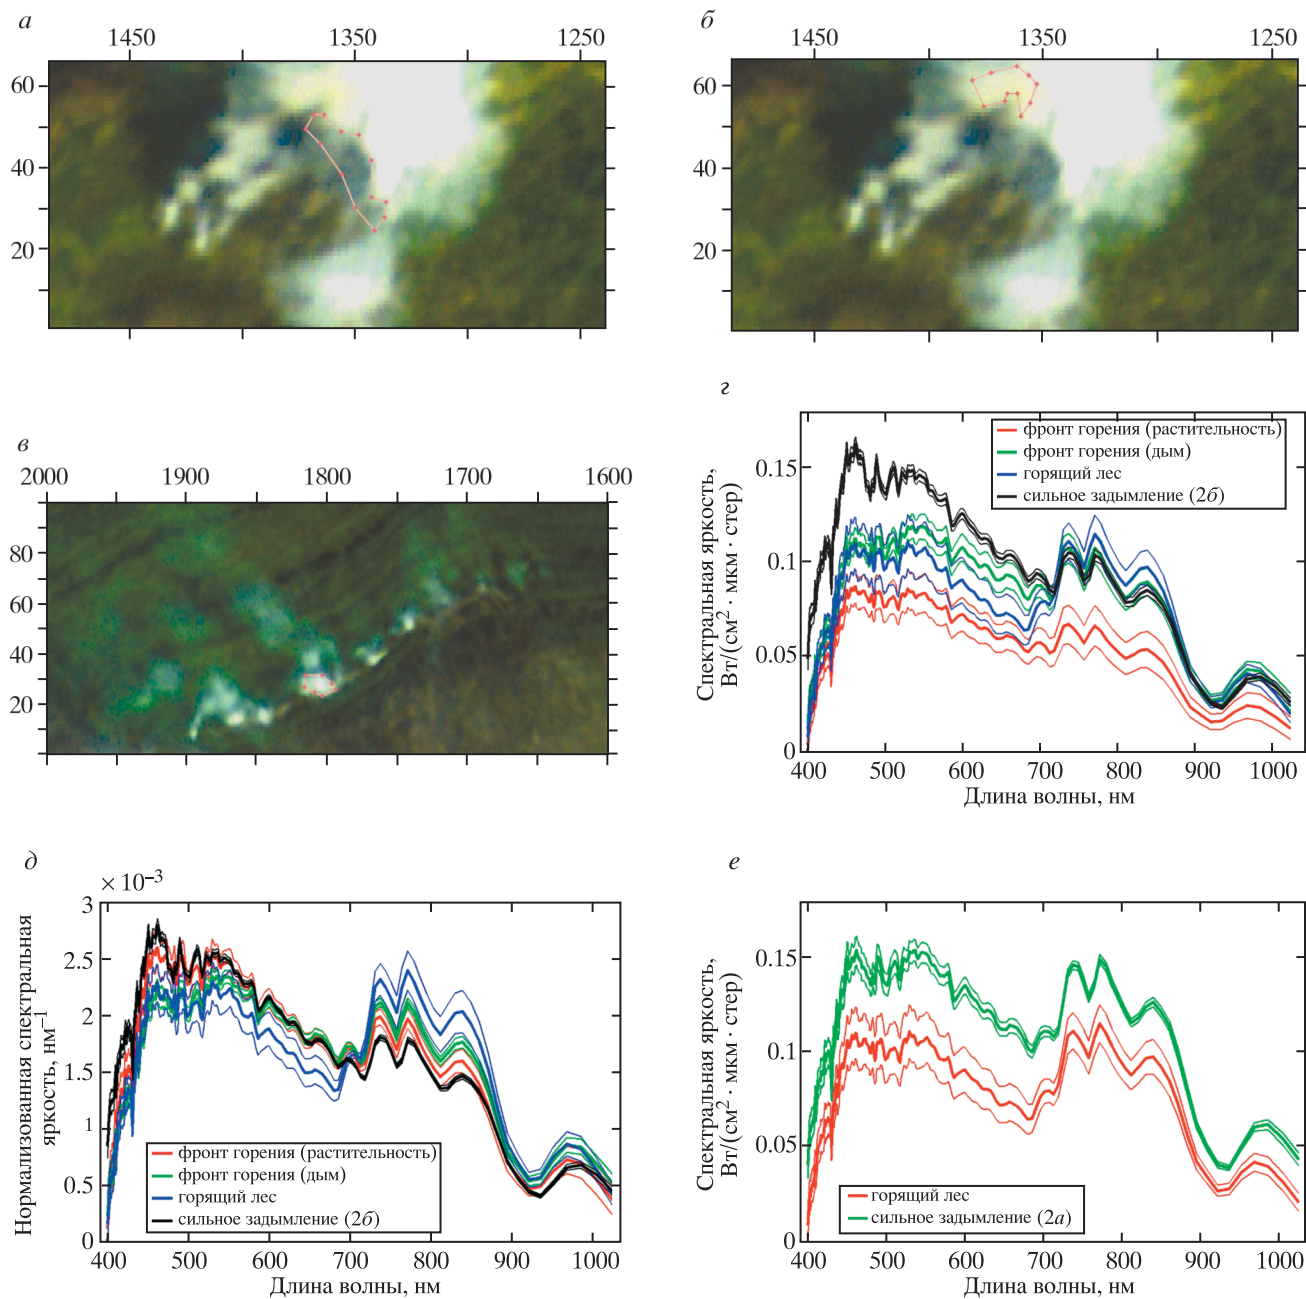


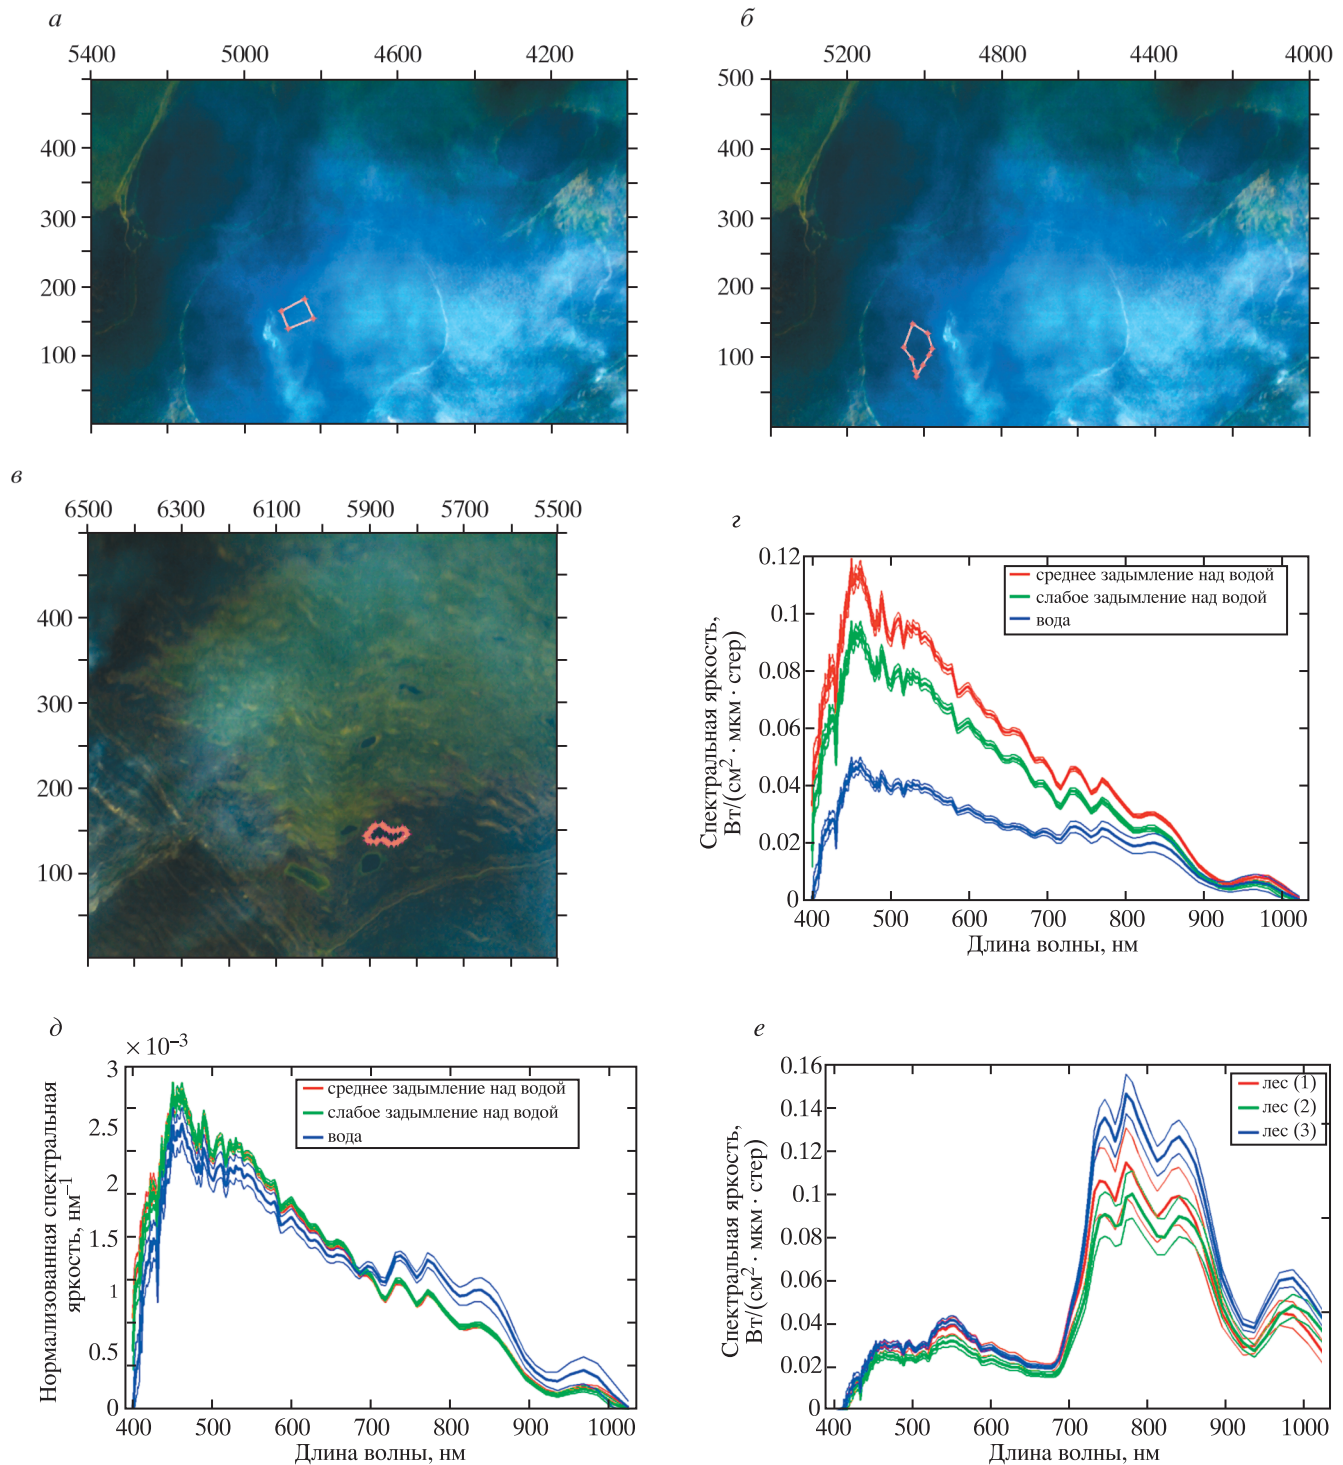
Рис. 2



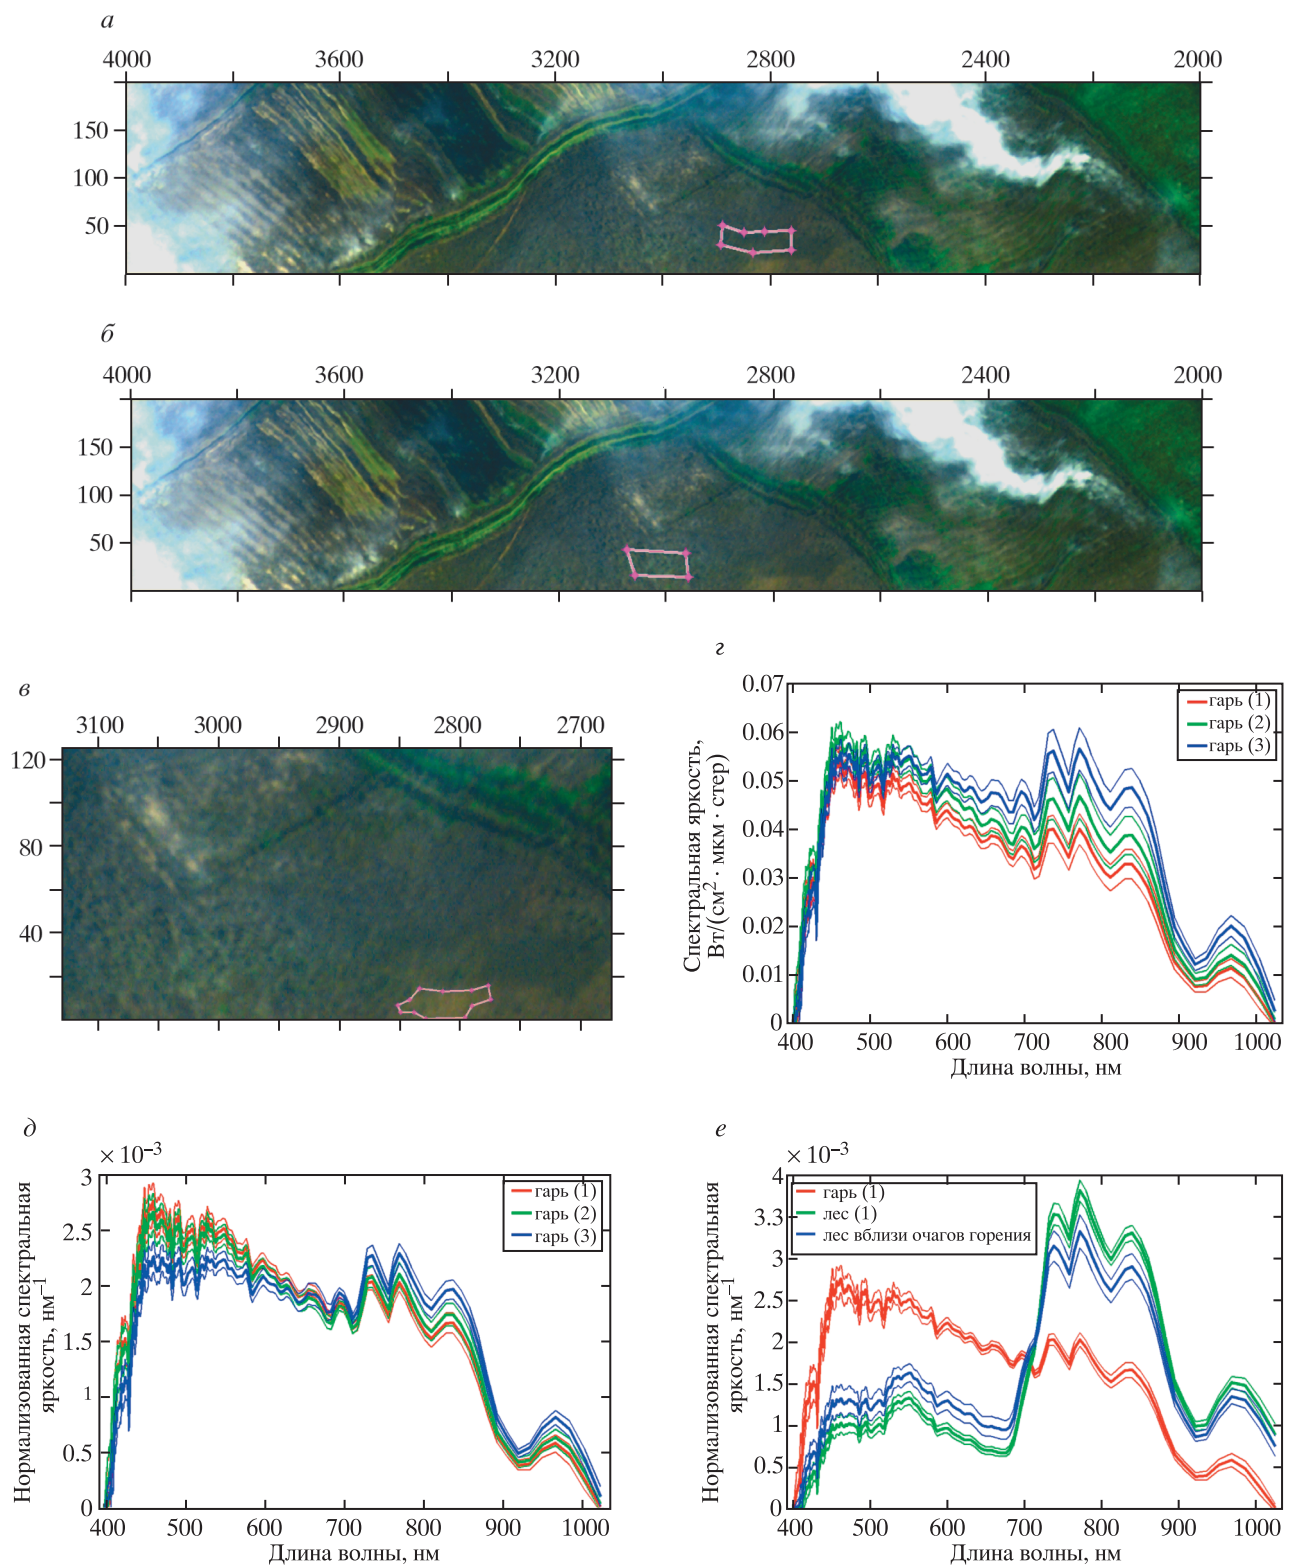


**Рис. 3.** RGB-синтезированные изображения гиперспектрметра с выделенными контурами для фронта интенсивного горения над лесной растительностью (а), над областью сильного задымления (б), над областью верхового лесного пожара (в), а также соответствующие этим контурам исходные и нормированные спектры вместе с их стандартными отклонениями в пределах оконтуренных областей (г, д). Кривые красного цвета соответствуют спектрам в пределах контура (а), зеленого цвета – в пределах контура (б), синего цвета – в пределах контура (в), черного цвета – в пределах контура рис. 2б. Для сравнения приведены спектры горящего леса и области сильного задымления (е). Число спектров для выделенных контуров: а – 390; б – 194; в – 131.

**Рис. 2.** RGB-синтезированные изображения гиперспектрметра с выделенными контурами сильного задымления, но разной интенсивности над двумя разными типами лесной растительности (а, б), среднего задымления (в), слабого задымления (г) и соответствующие этим контурам исходные спектры и их стандартные отклонения в пределах оконтуренных областей (д), а также нормированные спектры и их стандартные отклонения в пределах оконтуренных областей (е). Кривые красного и зеленого цвета соответствуют спектрам и их изменчивости в пределах контуров (а, б), синего цвета – в пределах контура (в), черного цвета – в пределах контура (г). Число спектров для выделенных контуров: а – 1813; б – 600; в – 3958; г – 4426.



**Рис. 4.** RGB-синтезированные изображения гиперспектрометра с выделенными контурами для дыма средней интенсивности (а), слабой интенсивности (б) над водной поверхностью и при фактическом отсутствии дыма над водой (в), а также соответствующие этим контурам исходные и нормированные спектры вместе с их стандартными отклонениями в пределах оконечных областей (г, д). Кривые красного цвета соответствуют спектрам в пределах контура (а), зеленого цвета – в пределах контура (б), синего цвета – в пределах контура (в). Для сравнения приведены исходные спектры различных типов леса, не подверженных пожарам (е), в правой части рис. 1. Число спектров для выделенных контуров: а – 2021; б – 2987; в – 1224.



**Рис. 5.** RGB-синтезированные изображения гиперспектрального изображения с выделенными контурами трех участков гарей (а, б, в) от предшествующих пожаров с незначительным влиянием дыма в текущий момент съемки, исходные (г) и нормированные (д) спектры этих участков и стандартные отклонения этих спектров, а также нормированные спектры одного из участков гари (красный цвет) при их сравнении с аналогичными спектрами нормально вегетирующей лесной растительности вдали от очага пожара (зеленый цвет) и вблизи от очага пожара (синий цвет) (е). Число спектров для выделенных контуров: а – 2740; б – 2707; в – 771.