

УДК 550.3+551.5

## Когнитивные технологии обработки оптических изображений высокого пространственного и спектрального разрешения

В.В. Козодеров<sup>1</sup>, Е.В. Дмитриев<sup>2</sup>, В.П. Каменцев<sup>3\*</sup>

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

<sup>2</sup>Институт вычислительной математики РАН  
117951, ГСП-1, г. Москва, ул. Губкина, 8

<sup>3</sup>Тверской государственный университет  
170100, г. Тверь, ул. Желябова, 33

Поступила в редакцию 3.03.2014 г.

Рассмотрены основные этапы развития технологий распознавания природно-техногенных объектов по данным дистанционного зондирования (когнитивных технологий обработки оптических изображений) в совокупности с вычислительными процедурами атмосферной коррекции многоспектральных и гиперспектральных аэрокосмических изображений. Основное внимание уделяется распознаванию лесных экосистем разного породного состава и возраста по данным летных испытаний отечественной гиперспектральной аппаратуры для выбранной тестовой территории, на которой проводились наземные лесотаксационные и другие обследования. Для отдельных градаций возрастов чистых березовых и сосновых насаждений показаны высокие точности распознавания таких объектов на основе разработанного программно-алгоритмического обеспечения обработки самолетных гиперспектральных изображений.

*Ключевые слова:* дистанционное зондирование, оптические изображения, распознавание объектов, лесная растительность разного породного состава и возраста; remote sensing, optical images, pattern recognition, forest canopies of various species and age.

### Введение

Появление первых оптических систем наблюдения атмосферы и земной поверхности со спутников стимулировало развитие двух основных направлений научно-технологических приложений данных дистанционного зондирования: распознавание наземных объектов и определение оптических характеристик атмосферы. Основная форма представления указанных данных — цифровые многоспектральные и гиперспектральные изображения. Исследования, касающиеся автоматизации визуального дешифрирования получаемых аэрокосмических изображений, берут свое начало из предшествующих научно-технологических разработок по созданию искусственного интеллекта, которые в настоящее время получили название когнитивных технологий.

Распознавание образов и анализ сцен — обширная область прикладной математики. В заданной предметной области исследований создаются алфавиты классов объектов, формируются словари характерных признаков этих объектов, разрабатываются вычислительные процедуры (классификаторы) пра-

вил принятия решения о принадлежности текущих элементов разрешения (пикселей) к известным априори. Первые примеры приложений этой дисциплины для обработки космических изображений были показаны в работе [1]. Одновременно разрабатывались методы теории переноса излучения, известные из астрофизики, теории ядерных реакторов, для оценки искажающего влияния атмосферы при обработке аэрокосмических изображений [2].

Первое из упомянутых направлений применения данных оптического зондирования прошло путь от построения моделей распознавания объектов на аэрокосмических изображениях при наличии шумов аппаратуры [3] через рассмотрение вычислительных процедур классификации объектов на этих изображениях [4] до современных представлений о контекстуальном распознавании текстур объектов с учетом контуров их границ как нечетких множеств [5]. Контекстуальное распознавание предполагает рассмотрение горизонтального влияния соседних пикселей для заданных классов объектов. Например, объект «лесная растительность определенного породного состава и возраста» формируется под влиянием пикселей, относящихся к освещенным солнцем и затененным участкам крон деревьев, пространственное распределение которых и характеризует соответствующий класс.

\* Владимир Васильевич Козодеров (vkozod@mail.ru); Егор Владимирович Дмитриев (yegor@mail.ru); Владимир Петрович Каменцев (kvp\_53@mail.ru).

Другое направление использования цифровых данных дистанционного зондирования стали называть атмосферной коррекцией аэрокосмических изображений и спектров [6]. Основу этих исследований составили численные методы решения краевых задач переноса излучения в атмосфере. Верхнее граничное условие моделирует отсутствие на верхней границе атмосферы рассеянного диффузного излучения. Нижнее граничное условие характеризует зависимости уходящего излучения от интенсивности падающего излучения и от оптических свойств земной поверхности [7]. Решение прямой задачи расчета излучения на разных уровнях атмосферы составило содержание известных вычислительных процедур LOWTRAN и MODTRAN соответственно низкого и среднего спектрального разрешения.

Обратная задача сводится к восстановлению характеристик объектов земной поверхности, связанных с их оптическими свойствами, по регистрируемым интенсивностям солнечного излучения [8]. Решение такого рода обратной задачи является значительно более сложным исследованием, чем нахождение оптической передаточной функции атмосферы – функции связи регистрируемых интенсивностей излучения на верхней границе атмосферы и на уровне земной поверхности.

Спектральные свойства объектов зависят от угловых условий съемки и оптического состояния атмосферы в момент съемки. Была создана специализированная аппаратура наземных измерений спектральной отражательной способности разных объектов в зависимости от угловых координат их дистанционного зондирования, и введена двулучевая функция отражательной способности [9]. В процессе создания базы данных спектральных измерений отражательной способности объектов с целью уменьшения влияния атмосферы при проведении наземных полевых кампаний обычно используются коэффициенты спектральной яркости как отношения регистрируемых в надир яркостей к яркости ортотропно отражающего экрана, находящегося в тех условиях освещения.

Сложности моделирования отражательной способности почвенно-растительного покрова, связанные с взаимным влиянием освещенных солнцем, затененных и промежуточных фитоэлементов, были устранены на основе новых подходов. Эти подходы развивались по мере повышения пространственного разрешения оптической аппаратуры дистанционного зондирования [10]. Первые попытки учета вертикальной плотности растительного покрова основывались на введении в рассмотрение индекса листовой поверхности (Leaf Area Index, или LAI) как некоторой характеристики экспоненциального ослабления интенсивности излучения средой растительности [11]. Прикладное значение индекса LAI связано с учетом свойств разной плотности полога в терминах некоторых эффективных характеристик рассеяния в нем падающего излучения. В работе [12] было показано, что это приближение применимо только для достаточно однородного покрова при отсутствии затенений и других эффектов, которые формируют данные по отражательной способности растительности.

В применении к оптическому зондированию лесных экосистем вместо индекса LAI возникла необходимость введения в явном виде в расчетный функционал регистрируемых интенсивностей излучения таких показателей, как плотность полога и ажурность крон деревьев [13]. При обращении основного функционала эти показатели позволяют определять параметры биологической продуктивности соответствующих экосистем по оптическим данным аэрокосмического зондирования. Были показаны преимущества этого нового приближения для оценки параметров состояния лесных экосистем [14].

Еще одно индексное приближение касается обработки многоспектральных данных дистанционного зондирования. Вегетационный индекс нормализованной разности (Normalized Difference Vegetation Index – NDVI) как некоторая комбинация каналов многоспектрального зондирования берет свое начало из описания данных невысокого пространственного разрешения для однородных объектов большой протяженности [15]. В [16] были показаны реальные ограничения этого приближения при обработке спутниковых изображений и необходимость использования нового приближения, позволяющего оценивать параметры биологической продуктивности лесных и других экосистем по многоспектральным данным дистанционного зондирования. Применение разработанного программно-алгоритмического обеспечения для распознавания лесной растительности разного породного состава и возраста при обработке самолетных гиперспектральных изображений демонстрируется в работе [17].

В настоящее время сформировалась область междисциплинарных исследований, связанная с оптимизацией обработки оптических изображений и оптимизацией каналов гиперспектрального зондирования. Решение возникающих прикладных задач позиционируется как нахождение оптимума некоторой целевой функции обработки изображений [18]. Оптимизация достигается определенной трансформацией изображений, которая формулируется в терминах вероятностных характеристик, таких как функция правдоподобия. При этом вводится информационная мера качества изображений [19], а при оптимизации каналов используется метод их последовательного дополнения, который обеспечивает возможное объединение каналов гиперспектрального зондирования без существенного уменьшения точности распознавания объектов [20].

Данная публикация дает некоторые примеры объединения перечисленных направлений научных исследований и технологических разработок в развитие основных результатов доведения машинно-обучающих алгоритмов распознавания объектов на изображениях до уровня, который обеспечивает опытный специалист-дешифровщик.

## Постановка задачи

Реализация когнитивных технологий обработки гиперспектральных аэрокосмических изображений высокого спектрального и пространственного разрешения

сводится к созданию алгоритмов выделения характерных признаков объектов на окружающем их фоне и принятия решений по возможной классификации образов этих объектов на основе сравнения выделенных признаков и текущих данных о состоянии объектов. Типичными являются две разные процедуры распознавания образов объектов по данным дистанционного зондирования: классификация с обучением; классификация без обучения, 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» на основе имеющихся группированных данных (обучающих выборок); «самообучение» (в некоторых случаях предполагается количество возможных классов), в котором алгоритм принятия решений строится таким образом, чтобы добиться малых внутриклассовых и больших межклассовых вариаций.

Принципы статистического распознавания образов основаны на том, что каждый образ объекта отображается как вектор в признаковом пространстве. Имея набор обучающих образов для каждого класса, можно решать задачу 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» разрешающей границы (с использованием, например, критерия среднеквадратичной ошибки) на основе обучающих образов. Указанные модели применимы для нахождения самых общих связей, в том числе нелинейных, между входными и выходными данными в процедурах распознавания образов.

В статистических процедурах распознавания образов обычно используются так называемое байесовское правило принятия решений, суть которого — в минимизации риска неправильных решений при использовании условных плотностей вероятностей отнесения конкретного вектора измерений к определенному классу. На практике указанные вероятности могут быть неизвестны, но они могут быть извлечены из имеющихся обучающих образов. В случае, когда предполагается принадлежность признаков некоторому параметрическому семейству распределений, говорят о параметрических классификаторах, обучение которых сводится к оценке неизвестных параметров. Если же форма плотности распределения неизвестна, то говорят о непараметрической модели классификации. В этом случае используются оценки плотности в пределах «окна» постоянного или адаптивного размера.

Качество классификатора зависит как от размера обучающей выборки, так и от ценности используемых выборочных данных. Неизбежно возникает

задача оптимизации характеристик классификатора, т.е. максимизации возможности его применения для обучающего набора данных, а также его способности к генерализации, т.е. к возможным приложениям классификатора для тестовых образов, которые изначально не закладывались на стадии обучения. Плохая способность к генерализации обусловлена следующими факторами: число признаков велико в сравнении с объемом выборочных данных; слишком велико число неизвестных параметров; классификатор излишне интенсивно оптимизирован на наборе обучающих данных. Этот последний из упомянутых случаев переобучения аналогичен процедуре переопределения в регрессии, когда становится слишком много свободных данных.

Перечисленные особенности реализации когнитивных технологий обработки оптических изображений изложены в [21]. Отметим два взаимосвязанных аспекта проблемы атмосферной коррекции изображений и нахождения оптимальных решений при распознавании объектов на этих изображениях. Первый из них основан на использовании феноменологической теории переноса (Radiative Transfer Model — RTM) [22] для преобразования регистрируемых яркостей в яркости на уровне земной поверхности (в упрощенном варианте восстановление альbedo поверхности). Второй аспект — это минимизация функции, названной энергией сцены, заданного фрагмента изображения или выбранного класса объектов на изображении.

Введение понятия энергии как целевой функции минимизации расхождений между регистрируемыми данными и свойствами распределений, аппроксимирующих эти данные, уточняет понятие классов на изображении (от однородных объектов до объектов с большим разнообразием регистрируемых яркостей). Если для каждого пикселя регистрируемая яркость есть «истина» плюс независимый гауссовский шум, то регуляризованное решение, которое переводит некорректно поставленную задачу в корректно поставленную, получается путем минимизации двух слагаемых энергии [23]. Первое слагаемое характеризует меру близости получаемого решения и регистрируемых яркостей пикселей для соответствующих классов объектов на изображении. Второе слагаемое — собственно регуляризатор, который накладывает априори ограничение на решение по сглаживанию используемых при этом теоретических функций распределения. Это может быть априорное предположение о постоянстве яркости пикселей в пределах оконтуренной сцены, о постоянстве градиента яркостей, о постоянстве кривизны соответствующей поверхности и т.д. Соответственно, ставится задача обнаружения объектов относительно окружающего фона с учетом реальных значений отношения сигнал-шум аппаратуры на обрабатываемых изображениях. Задача обнаружения формулируется как задача интерпретации каждого пикселя с помощью весовых функций составных элементов соответствующих объектов. Данный подход рассмотрен в [24].

Далее остановимся на некоторых примерах валидации информационной продукции обработки

самолетных гиперспектральных изображений, полученной с помощью отечественной аппаратуры, летные испытания которой проводились на тестовых участках в Тверской области.

## Обсуждение результатов

Одно из важных приложений гиперспектрального зондирования относится к распознаванию лесных экосистем разного породного состава и возраста. Биологи-лесники работают с наземными картосхемами лесотаксации, которые у них принято отображать в виде отдельных кварталов и выделов внутри них по преобладающей породе. Бонитет как основная характеристика качества древесины зависит от возраста и высоты древостоев. Ниже иллюстрируются некоторые результаты летно-полевой кампании 2011 г. по данным самолетного гиперспектрального зондирования и данным наземных лесотаксационных, геоботанических, лесотипологических (болотный, сфагновый, разнотравный и другие типы межкрупной растительности) обследований. Выделы на тестовой территории состоят в основном из сосны и березы.

Для составления базы данных наземных обследований нас интересовали только выделы с однородным породным составом. В таблице представлены параметры ансамблей спектральной плотности энергетической яркости (СПЭЯ) для пикселей, относящихся к таким «чистым выделам» (около 50 тыс. спектров на выбранной территории размером приблизительно 4×3 км). Эта площадь была покрыта 13 перекрывающимися изображениями, полученными в ходе самолетной съемки, каждое из которых имеет фиксированную ширину 500 пикселей и длину (вдоль траектории полета) порядка 2000 пикселей, с размером каждого пикселя на местности около 1×2 м соответственно. Указаны также дата (12 августа 2011 г.) и время съемки. Наибольшее разре-

шение по возрасту получилось для сосновых насаждений (14 возрастных градаций).

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 гиперспектральная камера (ГСК) обеспечивает высокие значения отношений сигнал-шум. Отражение затененными участками крон происходит более сложным образом. Здесь начинают играть роль многократное рассеяние света внутри кроны и спектральные свойства подстилающей поверхности. Кроме того, уровень сигнала ГСК значительно ниже и влияние собственной шумовой составляющей на формирование СПЭЯ отраженного излучения 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 ГСК). Для полученных обучающих выборок были рассчитаны интегральные яркости и разделены на 7 градаций 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 и реализация, попавшая в один из интервалов, относится к соответствующей градации.

На рис. 1, а представлены СПЭЯ молодого (13 лет) соснового древостоя с однородным породным составом. Наиболее заметны различия в спектрах длинноволновых каналов. Эти различия связаны с долей освещения солнцем крон деревьев: амплитуды спектров возрастают для соответствующих пикселей по мере увеличения доли освещения.

Параметры ансамблей СПЭЯ однородных древостоев

Порода	Возраст	Количество спектров	Трек-источник
Сосна	13	1046	2011-08-12=11-10-57
	16	2428	2011-08-12=11-31-32
	26	2061	2011-08-12=12-05-23
	36	447	2011-08-12=11-10-57
	47	5025	2011-08-12=11-17-58
	56	1807	2011-08-12=11-46-25
	66	7551	2011-08-12=11-52-48
	76	1557	2011-08-12=11-52-48
	76	4019	2011-08-12=11-59-25
	86	2055	2011-08-12=11-46-25
	96	3156	2011-08-12=11-38-02
	106	2191	2011-08-12=11-59-25
	116	644	2011-08-12=11-24-25
126	1932	2011-08-12=11-04-17	
136	695	2011-08-12=11-46-25	
Береза	16	1729	2011-08-12=11-31-32
	51	1634	2011-08-12=11-38-02
	71	5656	2011-08-12=11-46-25
Осина	11	2545	2011-08-12=11-38-02
Вяз	–	534	2011-08-12=10-47-53




Рис. 1. Распределение СПЭЯ соснового древостоя с однородным породным составом и возрастом 13 лет (*а*), нормированных значений СПЭЯ (*б*), те же распределения для однородных сосняков возрастом 66 лет (*в*) и нормированных значений (*г*). Обозначенные на рис. 1, *в* семь градаций яркости соответствуют пикселям с полностью освещенными кронами (1) и полностью затененному межкрупному пространству (7) с непрерывным переходом от этих крайних градаций к остальным по уровню солнечного освещения (2–6). Градации яркости на рис. 1, *а*, *б*, *г*, обозначенные оттенками серого цвета, соответствуют рис. 1, *в*

При решении задачи распознавания породного состава лесных выделов кажется затруднительным опираться непосредственно на значения соответствующих СПЭЯ, поскольку различие между спектрами отражения различных пород (а тем более возрастов) может быть гораздо менее выраженным, чем различие между затененными и освещенными участками. Кроме того, значения СПЭЯ существенным образом зависят от высоты солнца и текущих атмосферных условий. Для того чтобы сделать алгоритм распознавания более универсальным, необходимо в качестве признаков использовать СПЭЯ, нормированные на интегральную яркость (рис. 1, *б*).

Можно видеть, что разброс данных на рис. 1, *б* значительно меньше, чем на исходных данных рис. 1, *а*: на рис. 1, *б* спектры, соответствующие различным градациям интегральной яркости, практически сливаются. Это обусловлено тем, что для молодых древостоев характерна незначительная изрезанность верхней границы полога. Кроме того, сами размеры крон таковы, что они практически не разрешаются ГСК, —

характерный размер порядка 1 м. Таким образом, практически каждый пиксель содержит и освещенные, и затененные участки. Текстура таких выделов выглядит значительно более гладкой, чем для древостоев большего возраста.

Сказанное становится очевидным, если сравнить рис. 1, *а* и рис. 1, *в*, на которых изображены градации СПЭЯ молодых сосновых и приспевающих (возраст 66 лет) древостоев той же породы. В возрасте 66 лет крона и соответствующее межкрупное пространство разрешаются несколькими пикселями ГСК. Можно видеть, что на данных рис. 1, *в* градации освещенной части кроны имеют существенные вариации как в длинноволновых (700–1000 нм), так и в коротковолновых (400–700 нм) каналах ГСК.

При переходе к нормированным значениям СПЭЯ разброс резко уменьшается (рис. 1, *г*). Можно наблюдать инверсию амплитуд нормированных спектров (рис. 1, *в* и рис. 1, *г*): амплитуды, соответствующие затененным пикселям, начинают преобладать в коротковолновых каналах над амплитудами,

соответствующими освещенным пикселям. В то же время в длинноволновых каналах сохраняется превышение амплитуд спектров пикселей, соответствующих освещенным участкам кроны, над пикселями, соответствующими затененному межкроновому пространству.

По отобранным указанным образом ансамблям спектров можно сформировать по крайней мере три информационных слоя. Это пиксели, которые соответствуют полностью освещенным участкам кроны, полностью затененным участкам межкронового пространства и промежуточному уровню частично освещенных и частично затененных участков. Нормированные значения СПЭЯ были сохранены в виде массивов-ячеек (каждая ячейка содержит отдельную породу) по данным гиперспектрального самолетного зондирования при различных значениях проекционных характеристик лесного полога (плотность и сомкнутость крон).

Сформированные таким образом данные использовались для распознавания выбранных классов лесной растительности разного породного состава и возраста. Используемый для этих целей байесовский классификатор позволяет без труда разделить по спектральным признакам следующие группы объектов: водоемы, разные типы растительности, открытые почвы и т.п.

Следующий более сложный этап — это отбор отмеченных характерных признаков «чистых пород» деревьев и оценка вероятности ошибки классификации, но и здесь использовался байесовский классификатор для каждой группы пикселей, соответствующих вершинам крон, затененным участкам межкронового пространства и промежуточным условиям солнечного освещения.

Если объем обучающей выборки для каждого класса достаточно велик в этих тонких процедурах распознавания объектов лесного покрова по спектральным признакам, то для повышения устойчивости таких процедур удобно использовать известный метод кроссвалидации [25]. В этом методе обучающее множество (learning set) случайным образом разбивается на два подмножества: упомянутые выше «training» и «testing». Суть вычислительной процедуры в том, что классификатор обучается на основе первого из подмножеств, а ошибки классификации оцениваются независимым образом по второму из этих подмножеств. Такая процедура кроссвалидации реализуется  $N$  раз ( $N$  может быть достаточно велико), и на каждом шаге учитывается локально оптимальная последовательность признаков. Добиваются наиболее вероятной последовательности как единственного регуляризованного решения задачи классификации, поскольку в общем случае обнаруживается высокая чувствительность оптимальной последовательности признаков к малым вариациям обучающего множества.

Проведенные исследования показали, что в соответствии с изложенным здесь подходом ошибка распознавания зрелых сосняков и березняков по данным таблицы менее 2%. Ошибка распознавания молодняков этих пород достигает 5%.

Сложнее обстоит дело с распознаванием различий всей совокупности возрастов этих классов. Полная матрица ошибок при попиксельном сравнении реальных возрастов (см. таблицу) и представленных модельных результатов их восстановления для основных насаждений по данным гиперспектрального самолетного зондирования представлена на рис. 2 при дискретизации возрастов через каждые 10 лет.

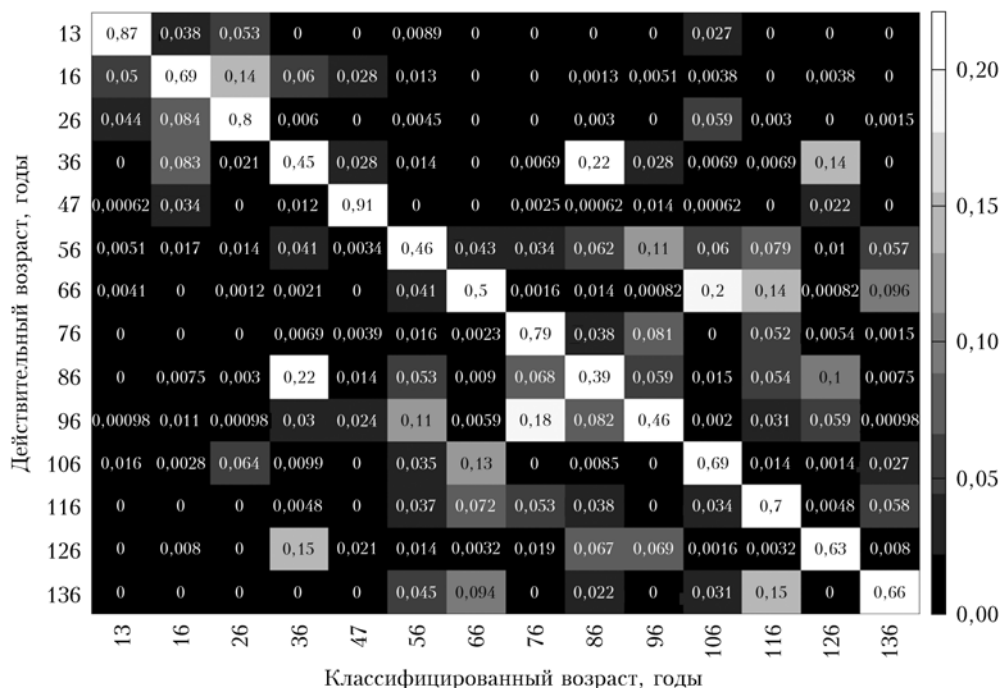


Рис. 2. Матрица ошибок (вероятности) для полностью освещенных солнцем участков крон чистых сосновых выделов всех возрастов на выбранных участках наземных обследований тестовой территории




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

При построении матрицы использовались только пиксели, соответствующие полностью освещенным участкам кроны. Как обычно, на главной диагонали стоят ошибки совпадения реальных и модельных данных, вне диагонали — ошибки «ложной тревоги» и «пропуска цели». Можно видеть, что неприемлемо высокими оказываются ошибки для некоторых возрастов: 36, 56, 66, 86 и 96 лет.

На рис. 3 приведена матрица ошибок для выбранных возрастов березовых (16, 51 и 71 лет, т.е. используются все данные таблицы по этой породе) и сосновых насаждений (16, 76 и 136 лет). Для этих дискретных возрастов точность решения задачи распознавания значительно выше: находится в пределах 80–88% для березняков и 95–99% для сосняков. Таким образом, распознавание всей совокупности возрастов (на примере сосняков от 13 до 136 лет) по данным самолетного гиперспектрального зондирования приводит к более существенным ошибкам, чем для выбранных дискретных возрастов.

### Заключение

Были описаны характерные особенности развития когнитивных технологий обработки гиперспектральных данных оптического зондирования в увязке с основными этапами обработки данных. Показаны принципы реализации когнитивных технологий на примерах обработки гиперспектральных изображений отечественной аппаратуры, которая в процессе ее летных испытаний устанавливалась на гиросtabilизированную платформу самолета вместе с аппаратурой аэрофотосъемки. Акцент сделан на распознавание лесной растительности разного породного со-

става и возраста на выбранной тестовой территории. Для отдельных возрастов демонстрируются очень высокие точности решения рассматриваемых прикладных задач.

Работа выполняется при финансовой поддержке проектов РФФИ № 13-01-00185 и 14-05-00598.

1. Дуда Р., Харп П. Распознавание образов и анализ сцен. М.: Мир, 1976. 509 с.
2. Козодеров В.В. Оценка искажающего влияния атмосферы при дешифрировании природных образований из космоса // Аэрокосмические исследования Земли. Обработка видеoinформации с использованием ЭВМ. М.: Наука, 1978. С. 24–35.
3. Jain A.K. Advances in mathematical models in image processing // Proc. IEEE. 1981. V. 69. P. 502–528.
4. Friedland N.S., Rosenfeld A. Compact object recognition using energy-function based optimization // IEEE Trans. Pattern Anal. Machine Intell. 1992. V. 14, iss. 7. P. 770–777.
5. Tso B., Olsen R.C. A contextual classification scheme based on MRF model with improved parameter estimation and multiscale fuzzy line process // Remote Sens. Environ. 2005. V. 97. P. 127–136.
6. Козодеров В.В. Атмосферная коррекция видеоизображений // Исслед. Земли из космоса. 1983. № 2. С. 65–75.
7. Li X.W., Strahler A.H., Woodcock C.E. A hybrid geometric optical-radiative transfer approach for modeling albedo and directional reflectance of discontinuous canopies // IEEE Trans. Geosci. Remote Sens. 1995. V. 33, N 2. P. 466–480.
8. Kondratyev K.Ya., Kozoderov V.V., Smokty O.I. Remote sensing of the Earth from space: atmospheric correction. Heidelberg: Springer-Verlag, 1992. 478 p.
9. Deering D.W. Field measurements of directional reflectance // Theory and Applications of Optical Remote Sensing. N.Y.: John Wiley & Sons, 1989. P. 14–65.

10. Curran P.J., Foody G.M., Kondratyev K.Ya., Kozoderov V.V., Fedchenko P.P. Remote sensing of soils and vegetation in the USSR. London: Taylor and Francis, 1990. 203 p.
11. Breda N. Ground-based measurements of leaf area index: A review of methods, instruments and current controversies // J. Experim. Botany. 2003. V. 54, iss. 392. P. 2403–2417.
12. Козодеров В.В. Особенности реализации моделей оценки фитомассы растительности по наблюдениям из космоса // Исслед. Земли из космоса. 2006. № 2. С. 79–88.
13. Козодеров В.В., Косолапов В.С. Оптическое зондирование биосферы по многоспектральным аэрокосмическим изображениям // Оптика атмосф. 1992. Т. 5, № 8. С. 852–859.
14. Kozoderov V.V. A scientific approach to employ monitoring and modeling techniques for Global Change and Terrestrial Ecosystems and other related projects // J. Biogeogr. 1995. V. 22, N 415. P. 927–933.
15. Prince S.D., Justice C.O., Eds., Coarse resolution remote sensing of the Sahelian environment // Int. J. Remote Sens. 1991. V. 12, N 6. P. 1133–1421.
16. Kozoderov V.V., Dmitriev E.V. Remote sensing of soils and vegetation: regional aspects // Int. J. Remote Sens. 2008. V. 29, N 9. P. 2733–2748.
17. Kozoderov V.V., Dmitriev E.V. Remote sensing of soils and vegetation: pattern recognition and forest stand structure assessment // Int. J. Remote Sens. 2011. V. 32, N 20. P. 5699–5717.
18. Li S.Z. Markov random field modeling in computer vision. New York; Berlin; Heidelberg; Tokyo: Springer-Verlag, 1995. 350 p.
19. Козодеров В.В. Применение данных оптического дистанционного зондирования для изучения природно-климатических процессов // Климат и природа. 2012. Т. 3, № 2. С. 3–16.
20. Козодеров В.В., Дмитриев Е.В., Каменцев В.П. Система обработки самолетных изображений лесных экосистем по данным высокого спектрального и пространственного разрешения // Исслед. Земли из космоса. 2013. № 6. С. 57–64.
21. Козодеров В.В., Кондранин Т.В., Дмитриев Е.В. Тематическая обработка многоспектральных и гиперспектральных аэрокосмических изображений: Уч. пособие. М.: Изд-во МФТИ, 2013. 225 с.
22. Белов В.В., Тарасенков М.В. О точности и быстродействию RTM-алгоритмов атмосферной коррекции спутниковых изображений в видимом и УФ-диапазонах // Оптика атмосф. и океана. 2013. Т. 26, № 7. С. 564–571.
23. Козодеров В.В., Кондранин Т.В., Дмитриев Е.В., Казанцев О.Ю., Персев И.В., Щербаков М.В. Обработка данных гиперспектрального зондирования // Исслед. Земли из космоса. 2012. № 5. С. 3–11.
24. Анищенко А.В., Огреб С.М., Юхно П.М. Сравнительный анализ панхроматического и многоспектрального режимов обнаружения пространственных объектов // Оптика атмосф. и океана. 2013. Т. 26, № 8. С. 673–678.
25. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning. N.Y.: Springer, 2001. 765 p.

*V.V. Kozoderov, E.V. Dmitriev, V.P. Kamentsev. Cognitive technologies for processing optical images of high spatial and spectral resolution.*

Main stages of development of technologies for natural and anthropogenic objects recognition (cognitive technologies for optical images processing) using remote sensing data are considered together with computational procedures of atmospheric correction of multispectral and hyperspectral airspace images. Main attention is paid to recognition of forest ecosystems of various species and age, based on in-flight testing of a domestic imaging spectrometer for a selected test area, where ground-based forest inventory and other observations were carried out. High accuracies of the recognition of separate gradations of ages for the selected pure birch and pine species are revealed, using the elaborated software for airborne hyperspectral image processing.