

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 528.72 : 004.93

СПЕКТРАЛЬНО-ПРОСТРАНСТВЕННЫЕ МЕТОДЫ КЛАССИФИКАЦИИ ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ. ОБЗОР*

С. М. Борзов, О. И. Потатуркин

*Институт автоматизации и электрометрии СО РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 1
E-mail: borzov@iae.nsk.su
potaturkin@iae.nsk.su*

Выполнен обзор методов спектрально-пространственной классификации гиперспектральных данных. Рассмотрены публикации, посвящённые наиболее популярным способам использования пространственной информации для повышения точности результирующих картосхем. Показано, что лучшие результаты достигаются при применении предварительной обработки «сырых» данных до выполнения процедур попиксельной спектральной классификации. Рассмотрены и проанализированы недостатки, ограничения и возможные направления развития существующих подходов.

Ключевые слова: дистанционное зондирование Земли, гиперспектральные изображения, классификация типов поверхностей, спектральные и пространственные признаки.

DOI: 10.15372/AUT20180607

Введение. В настоящее время развитие средств дистанционного зондирования Земли (ДЗЗ) характеризуется внедрением технологий гиперспектральной (ГС) съёмки в видимом и ближнем инфракрасном диапазонах [1, 2]. Отличительной особенностью регистрируемых при такой съёмке изображений является большое количество каналов и узкая ширина каждого из них. За счёт этого ГС-изображения потенциально обладают значительно большими возможностями при решении многих научных и практических задач. Однако для их анализа требуется создание специализированных методов и алгоритмов обработки данных.

Классификация типов подстилающей поверхности по мультиспектральным данным ДЗЗ традиционно осуществляется на основе анализа диаграмм рассеяния значений пикселей в многомерном пространстве признаков, в качестве которых используется яркость в отдельных каналах. Процедура состоит из обучения и собственно классификации, т. е. отнесения пикселей к наиболее близкому классу. На первом этапе в многомерном пространстве признаков на основе анализа наборов пикселей, для которых известны классы (обучающих выборок), определяются области (кластеры), где наиболее часто встречаются пиксели каждого из классов [3]. На втором — рассчитывается близость остальных пикселей изображения к каждому из образованных кластеров и находится среди них ближайший. Методы классификации различаются между собой в первую очередь способом определения указанной близости. Но прямое использование для обработки ГС-данных классификаторов, разработанных для анализа мультиспектральных изображений, сопровождается

*Работа выполнена при финансовой поддержке Федерального агентства научных организаций (государственная регистрация № АААА-А17-117052410034-6).

высокими вычислительными затратами и требует больших объёмов обучающих выборок [4]. Кроме того, проблема заключается в том, что при анализе ГС-изображений слабо различимых типов подстилающей поверхности классические попиксельные методы демонстрируют недостаточно большую точность. Это обусловлено несколькими причинами. Во-первых, спектральный состав пикселя является комбинацией спектральных характеристик объектов, образующих этот пиксель [5]. Во-вторых, различные участки поверхности оказываются в разных условиях. Одни освещены прямым солнечным излучением, другие находятся в тени и освещаются отражённым или рассеянным светом [6]. Кроме того, у них различная ориентация поверхности по отношению к источнику освещения и регистрирующей системе и различная влажность. Значительные искажения в результирующие спектры вносит также переотражение между слоями, такими как вода—почва, растительность—почва и т. п. Это приводит к тому, что для широкого круга практических приложений спектральных признаков оказывается недостаточно [7].

Повышение достоверности классификации ГС-изображений может быть достигнуто путём одновременного анализа характеристик каждого пикселя и характеристик пикселей его ближайшей окрестности, т. е. за счёт совместного анализа спектральных и пространственных признаков. Действительно, при мульти- и гиперспектральной съёмках поверхности Земли пиксели изображений, как правило, не являются абсолютно независимыми. Это обусловлено следующими причинами:

— каждый пиксель образуется не только излучением, отражённым от соответствующей площадки подстилающей поверхности, но и рассеянным излучением от объектов вне этой площадки, причём чем ближе данный объект к указанной площадке, тем больше его влияние;

— большинство объектов, находящихся на поверхности Земли, по своим размерам таковы, что образуют изображение, значительно превышающее размер пикселей, таким образом, соседние пиксели с большой долей вероятности относятся к одному и тому же классу.

Спектральные же методы классификации рассматривают обрабатываемые данные не как изображения, а как совокупность результатов независимых спектральных измерений, и эти факты не учитываются.

Пространственная информация особенно важна для изображений с высоким пространственным разрешением при обнаружении и распознавании антропогенных объектов. Однако вопрос, каким образом следует её учитывать при анализе гиперспектральных изображений, несмотря на его активное обсуждение в научной литературе, на сегодняшний день остаётся открытым.

Наиболее известный способ учёта пространственных признаков при обработке мультиспектральных данных основан на предварительном разделении изображения на относительно однородные области и их последующей классификации с использованием спектральных, текстурных и геометрических признаков полученных сегментов, а также их взаимного положения. Исторически первым алгоритмом, реализующим данный способ, является алгоритм ЕСНО (Extraction and Classification of Homogeneous Objects) [8, 9]. В дальнейшем такой подход получил широкое развитие и в научной литературе называется объектно-ориентированным подходом (например, [10, 11]). За последние несколько десятилетий он показал свою эффективность при обработке изображений высокого пространственного разрешения. И хотя в работах, посвящённых классификации ГС-изображений, термин объектно-ориентированный подход используется значительно реже, основные его положения, несомненно, оказали большое влияние на принципы формирования алгоритмов спектрально-пространственной классификации.

В целом методы спектрально-пространственной классификации ГС-изображений могут быть разделены на три категории. Первая использует пространственную зависимость

на этапе предварительной обработки для того, чтобы уточнить значения пикселей в исходных данных путём применения различных пространственных фильтров. Это могут быть как обычные сглаживающие фильтры, так и $2D$ -фильтры Габор [12–15], морфологические профили [16–19], энтропия [20], атрибутные профили [21], эмпирические моды [22, 23].

Вторая осуществляет учёт пространственной зависимости на этапе постобработки для уточнения классов пикселей путём анализа картосхем и/или карт вероятности классификации, сформированных алгоритмами попиксельной спектральной классификации. Наиболее известным методом данной категории является мажоритарная обработка [24, 25].

Третья категория методов спектрально-пространственной классификации совмещает пространственную и спектральную информацию для получения комбинированных признаков. При реализации этого подхода трёхмерный массив ГС-данных обрабатывается с применением $3D$ -ядер. Примерами таких ядер являются трёхмерные вейвлет-фильтры [26], $3D$ -фильтры Габор [27, 28] или трёхмерные распределённые вейвлет-фильтры [29], формируемые на различных масштабах и частотах. Последняя категория методов непосредственно использует трёхмерную (x, y, λ) природу ГС-данных и потенциально может привести к выделению более значимых признаков, содержащих важную информацию о локальных изменениях сигнала в его спектральном и пространственных измерениях.

Целью данной работы является анализ существующих методов комбинированной спектрально-пространственной классификации ГС-данных ДЗЗ. Особое внимание уделяется рассмотрению различных способов включения пространственной информации в процесс классификации ГС-изображений для повышения его эффективности.

Методы на основе уточнения значений пикселей в исходных данных на этапе предварительной обработки путём учёта их окрестностей. В первую очередь к данной категории следует отнести алгоритмы [30–32], которые напрямую используют идею о том, что каждый пиксель в ГС-изображении и его ближайшие соседи принадлежат к одному и тому же типу поверхности и имеют схожие спектральные характеристики. Исходя из этого, если центральный пиксель по какой-то причине искажён, то каждый пиксель окрестности может рассматриваться как гипотеза для определения его точного значения. В [30], в частности, предлагается любой пиксель изображения представлять некоторой линейной комбинацией его соседей, а весовые коэффициенты определять согласно их близости по параметрам к центральному. Для этих целей используется метод регуляризации Тихонова [33]. Данный подход в иностранной литературе получил название *multihypothesis (MH) prediction-based* (многогипотезное предсказание) и реализуется в комбинации с различными методами спектральной классификации. В работах [31, 32] показано, что при малых объёмах обучающих выборок он наиболее эффективен в сочетании с методом опорных векторов (SVM — Support Vector Machines) [14, 34]. В [32] отмечается, что низкочастотная фильтрация — это особый случай *multihypothesis prediction*, где веса для гипотез одинаковые и равны $1/L$ (L — число пикселей в окрестности), так что предсказанное значение становится средним по окрестности.

В работах [12, 13, 15, 35] предлагается учитывать спектрально-пространственную информацию для классификации ГС-изображений путём фильтрации Габор. Признаки на основе фильтров Габор в настоящее время успешно применяются для анализа мультиспектральных изображений. Они позволяют выделять некоторые подобные объекту структуры на изображении с учётом их ориентации, используя свёртку с пространственным ядром специальной формы (рис. 1).

Результат свёртки с ядрами различной ориентации представляется в виде вектора признаков. Векторы пространственных и спектральных признаков нормализуются (для получения единичной дисперсии) и классифицируются с помощью метода SVM [12, 13, 35] или нейронных сетей глубокого машинного обучения (KELM — Kernel Extreme Learning

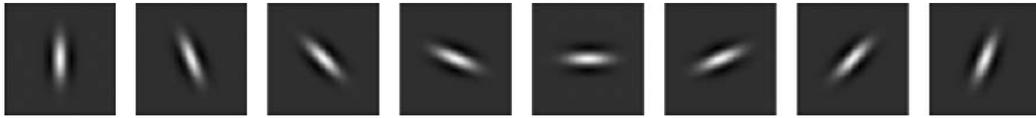


Рис. 1. Двумерные ядра фильтра Габора с различной ориентацией [15]

Machine) [12, 15, 36]. В [15] на примере двух реальных гиперспектральных наборов данных исследована эффективность классификатора KELM на основе фильтрации Габора (Gabor-filtering-based KELM) и многогипотезного предсказания (MH-prediction-based KELM). Блок-схемы методов представлены на рис. 2. Показано, что предложенные методы по эффективности превосходят обычные попиксельные классификаторы, такие как Gabor-filtering-based SVM [12, 13, 35] и MH-prediction-based SVM [30–32].

Следует также отметить алгоритмы, исследованные в работах [22, 23]. Они основаны на предварительном разложении изображения на сглаженные в различной степени с использованием эмпирических мод [37] (EMD — Empirical Mode Decomposition) и сокращении размерности пространства признаков с применением дискретного вейвлет-преобразования (DWT — Discrete Wavelet Transform) и метода главных компонент (PCA — Principal Component Analysis). Разложение на эмпирические моды (в отличие от гармонического анализа, где модель сигнала задаётся заранее) представляет собой итерационную вычислительную процедуру, в результате которой исходные данные раскладываются на внутренние колебания (IMF — Intrinsic Mode Functions). В [12, 22] использован алгоритм, схема которого показана на рис. 3.

На первом этапе в каждом канале ГС-изображения выполняется разложение с помощью метода EMD. Изображение раскладывается на четыре наиболее информативные собственные моды (IMF). Возникают четыре ГС-изображения с различной степенью пространственного размытия. Затем выполняется одномерное вейвлет-преобразование для каждого пикселя всех четырёх ГС-изображений для сокращения количества признаков, в результате чего формируются WIMF1–4. Далее изображения соответствующих каналов складываются между собой с образованием новых изображений. Суммирование WIMF1 и WIMF2 даёт WIMF12 и т. д. Полученные признаки анализируются с помощью SVM-классификатора. В качестве критерия эффективности классификации используется результирующая точность, определяемая как выраженное в процентах отношение количества верно классифицированных пикселей к их общему количеству. Утверждается, что данный алгоритм при обработке широко распространённого фрагмента тестового изображения, полученного в рамках программы AVIRIS (Airborne Visible Infrared Imaging

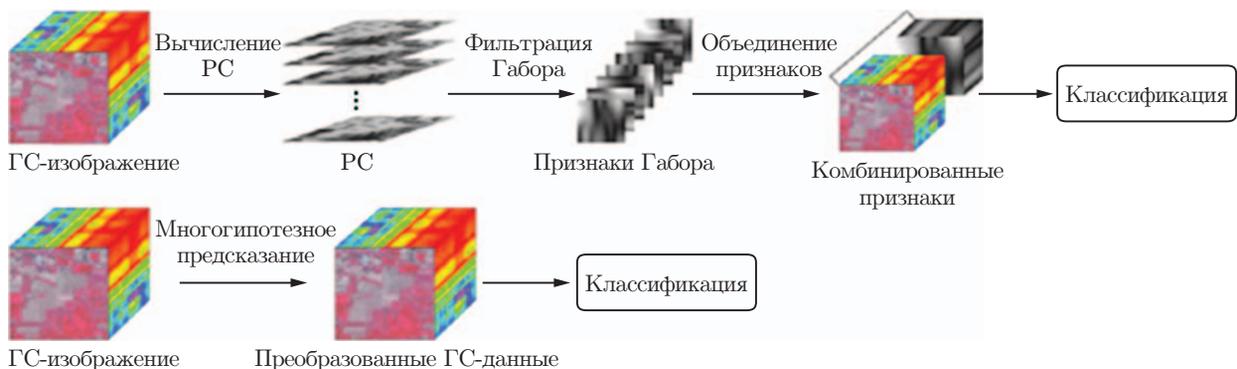


Рис. 2. Блок-схема алгоритмов классификации на основе двумерного фильтра Габора и многогипотезного предсказания [15]

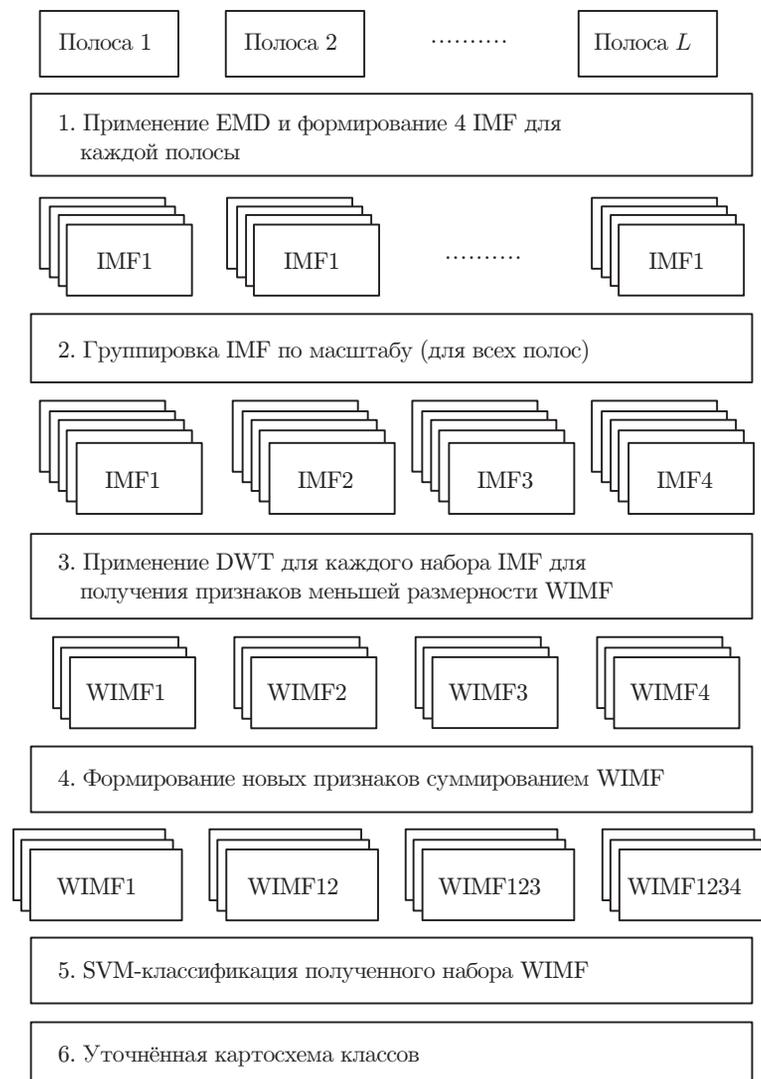


Рис. 3. Алгоритм, основанный на сглаживании изображений и сокращении размерности пространства признаков с применением вейвлет-преобразований [22]

Spectrometer) на опытном полигоне «Индиан Пайнс» (штат Индиана, США) [38], позволил достичь точности 98,63 %.

Направление, связанное с применением предварительной пространственной обработки ГС-данных, получило дальнейшее развитие благодаря инструментарию многоградационной морфологической фильтрации. Понятие «морфологические профили» (MP — Morphological Profile) введено в работе [39]. Они представляют собой многомасштабное разложение изображений с использованием операций открытия и закрытия, которые определены в математической морфологии [40] в виде последовательных операций эрозии и дилатации. Фактически с их помощью из одного изображения строится серия изображений с уменьшающейся степенью подробности его описания, но с сохранением чёткости и положения границ зон. В дальнейшем вся полученная серия используется для классификации исходного изображения. Морфологические профили продемонстрировали свою эффективность при классификации панхроматических изображений высокого пространственного разрешения. В частности, в [41] аппарат морфологических профилей применён для выделения сети дорог.

Продолжение исследований в области выделения пространственных признаков на изображении посредством MP привело к идее использовать морфологические атрибутив-

ные фильтры [42], с помощью которых обрабатываются входные изображения, с удалением связанных компонент, не удовлетворяющих заданным критериям. В качестве атрибутов могут использоваться чисто геометрические параметры (площадь, периметр, геометрические моменты, факторы формы), текстурные характеристики (среднее, СКО, энтропия) и др. Атрибутами могут быть любые количественно определяемые меры регионов (связанных компонент, представленных на изображении). В [43] продемонстрировано использование морфологических атрибутивных фильтров для классификации изображений сверхвысокого разрешения. В [44] по аналогии с МР введены атрибутивные профили (AP — Attribute Profiles).

При распространении инструментов математической морфологии на ГС-данные в [17] рассматривается возможность уменьшения исходной размерности пространства спектральных признаков с помощью метода PCA с последующим вычислением МР для каждой из первых главных компонент.

Объединение вычисленных морфологических профилей для разных главных компонент ведёт к образованию расширенного морфологического профиля (EMR — Extended Morphological Profile). Признаки, выделенные с помощью EMR, в различных работах были использованы для классификации ГС-изображений с помощью нейронных сетей [17], случайного леса (RF — Random Forests) [45] и метода опорных векторов [19]. В последней работе EMR рассматривался совместно с полной спектральной информацией (без предварительного выделения главных компонент).

В [46] вводится понятие расширенных атрибутивных профилей (EAR — Extended Attribute Profiles) и расширенных многоатрибутивных профилей (EMAP — Extended Multi-Attribute Profiles), которые ориентированы на использование AP при обработке гиперспектральных данных: EAR формируется применением одного атрибутивного фильтра к различным каналам изображения (чаще всего к нескольким первым главным компонентам), EMAP объединяет несколько EAR, т. е. формируется применением нескольких фильтров к нескольким каналам изображения. С одной стороны, это ведёт к существенному увеличению размерности пространства выделенных признаков, с другой — к большей точности описания пространственных характеристик данных.

Для анализа изображений с помощью AP предложено использовать древовидную структуру (рис. 4). Дерево строится от корня, который представляет полное изображение с его уровнями яркости, к вершинам, соответствующим связным областям. Веса рёбер соответствуют значениям определённого атрибута, уровни дерева — яркости областей.

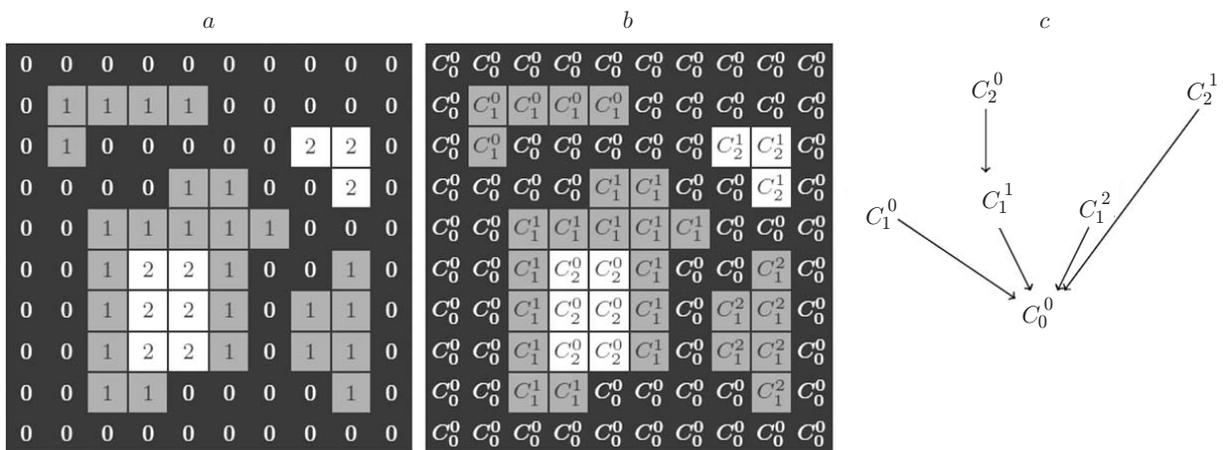


Рис. 4. Пример построения дерева по трёхградационному изображению [46]: a — исходное изображение, b — выделенные однородные компоненты на изображении, c — сформированное дерево по исходному изображению

Связи (рёбра) устанавливаются между соприкасающимися областями. Процедура фильтрации состоит из трёх этапов: 1 — создание дерева, 2 — оценивание атрибута, 3 — восстановление изображения. Цель первого этапа — представить изображение в виде дерева, и это наиболее трудоёмкая операция. На втором этапе вычисляется требуемый атрибут и сравнивается со значением заданного порога. Узел, который не удовлетворяет критерию, удаляется, а остальные сохраняются. На третьем этапе полученное трансформированное дерево используется для формирования результирующего изображения.

Предложенный инструментарий исследован в [46] на двух реальных изображениях. Здесь использовались четыре атрибута: площадь, диагональ ограничивающего прямоугольника, момент инерции и СКО. Соответственно были получены четыре ЕАР и объединены в один ЕМАР. Классификация выполнялась с помощью алгоритма RF (случайный лес). Для сравнения были также получены результаты классификации с использованием главных компонент и ЕМАР. Показано, что метод на основе ЕМАР позволяет получить лучшую точность классификации, что объясняется его способностью более точно описывать пространственные признаки изображений.

Морфологические атрибутивные профили, по всей видимости, — наиболее гибкий инструментарий для выделения пространственной информации при анализе данных ДЗЗ. Поскольку они впервые появились в поле зрения исследователей достаточно недавно (в начале века), такой подход в настоящее время получает дальнейшее развитие, связанное со всё большим и большим его усложнением. Так, в [47] предлагается применять для классификации ГС-изображений уже многомерные атрибутивные фильтры, в [48] — выделять статистические и геометрические признаки связанных компонент на изображении и формировать признаковые профили (FP — Feature Profiles). В качестве признаков используются параметры гистограмм [49, 50] или различные локальные статистические признаки первого порядка [51, 52]. В [53, 54] атрибутивные профили апробируются с различными вариантами обучения. Более подробно существующие спектрально-пространственные подходы, использующие различные технологии выделения спектральных признаков и пространственной обработки с помощью АР, рассматриваются в обзорах [18, 55].

Методы на основе уточнения классов пикселей путём обработки картосхем попиксельной спектральной классификации. Данные алгоритмы основаны на анализе картосхем классов, сформированных в результате выполнения алгоритмов попиксельной классификации, и их уточнении. Наиболее известный и широко используемый способ повышения точности классификации называется мажоритарной обработкой [24, 25] и заключается в выборе для каждой окрестности заранее заданной формы наиболее часто встречающегося класса. В более общем случае независимо выполняются попиксельная классификация и сегментация изображения, и затем для каждого сформированного сегмента выбирается класс как класс большинства пикселей в этом сегменте (например, в [56]) (рис. 5).

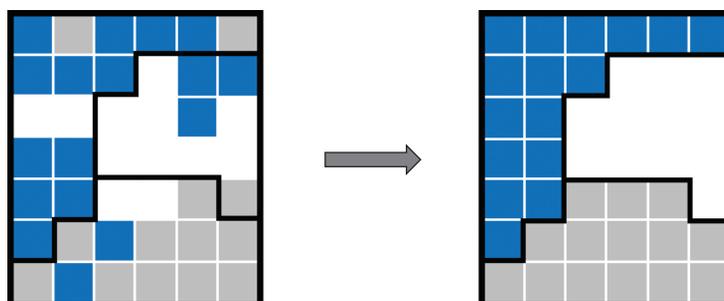


Рис. 5. Процесс объединения данных попиксельной классификации и сегментации [56]

Данный метод может быть модифицирован с помощью алгоритма уточнения класса пикселей с низким уровнем достоверности (ниже определённого порога) по классам пикселей его окрестности. При реализации алгоритма на этапе попиксельной спектральной классификации формируются картосхема классов и карта вероятности классификации, отражающая достоверность отнесения пикселей к каждому из классов. Далее для уточнения результатов процедуры классификации используется информация о том, с какой вероятностью каждый пиксель относится к тому классу, который присвоен ему в картосхеме. С этой целью для всех пикселей с вероятностью ниже заданной класс уточняется с помощью мажоритарной обработки, учитывающей только те пиксели окрестности, для которых класс определён. Затем для уменьшения раздробленности полученной картосхемы проводится обычная мажоритарная обработка.

Другая модификация данного метода заключается в уточнении класса пикселей путём мажоритарной обработки картосхем с учётом вероятности отнесения пикселей окрестности к каждому классу (вероятностный мажоритарный фильтр) [57]. При его реализации, как и в предыдущем случае, учитывается вероятность отнесения каждого пикселя к присвоенному ему классу. Можно считать, что таким образом пиксель голосует за этот класс, а вес голоса равен соответствующей вероятности. Суть заключается в том, чтобы в окрестности обрабатываемого пикселя найти суммарный вес голосов каждого класса, а затем присвоить этому пикселю номер класса с наибольшим суммарным весом. Обработка выполняется скользящим окном заданного размера.

В ряде исследований обработка ГС-изображений осуществляется на основе вероятностного классификатора и пространственной обработки карт вероятности классификации путём минимизации так называемой энергетической функции, при этом алгоритмы отличаются в первую очередь способами её определения. В [58] используется вероятностный метод SVM-классификации. Как и ранее, строятся первичная картосхема классов и карта вероятности классификации. Затем они совместно обрабатываются в целях их уточнения с использованием марковских случайных полей (MRF). Для этого рассчитывается энергетическая функция:

$$U = U_{\text{spectral}} + U_{\text{spatial}},$$

$$U_{\text{spectral}}(x_i) = -\ln(P(x_i | L_i)), \quad U_{\text{spatial}}(x_i) = \sum \beta(1 - \delta(L_i, L_j)),$$

где $P(x_i | L_i)$ — вероятность отнесения пикселя x_i к классу L_i , $\delta(\cdot, \cdot)$ — символ Кронекера, β — подбираемый весовой коэффициент. Другими словами, спектральная составляющая энергетической функции определяется вероятностью отнесения пикселя к выбранному классу, а пространственная — количеством пикселей в окрестности, отнесённых к этому же классу. Далее выполняется пространственное регулирование: случайно выбранному пикселю меняется установленный на первом этапе класс и проверяется суммарная энергия окрестности. Если она уменьшилась, ему присваивается новый класс. Процедура многократно повторяется. В частности, предложена модификация этого алгоритма, учитывающая градиентное изображение для сохранения границ и малых объектов (рис. 6). При подсчёте пространственной составляющей энергии окрестности градиент используется как весовой коэффициент, являющийся функцией от координат.

В [59] применён похожий подход, энергетическая функция строится как сумма потенциала самого пикселя и потенциалов пар пикселей (центрального и из ближайшей окрестности), вычисляемых по карте вероятности классификации с использованием дивергенции Кульбака — Лейблера. Сначала на основе обработки данных обучающей выборки находятся весовые коэффициенты при этих потенциалах. Сумма потенциалов с весовыми коэффициентами и будет определять результат при дальнейшей классификации.

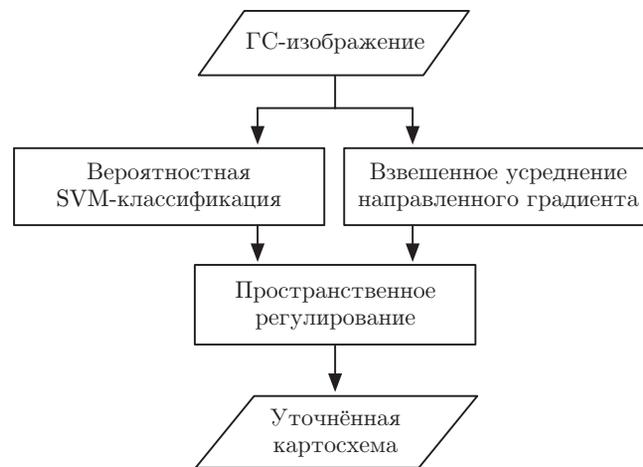


Рис. 6. Блок-схема алгоритма классификации с постобработкой картосхемы с применением MRF [58]

В работе [60] энергетическая функция также вычисляется как сумма энергии данных и энергии взаимодействия. Член энергии данных вычисляется, как и ранее, по результату вероятностной SVM-классификации. Второй член энергии, выражающий взаимодействие между пространственно-смежными пикселями, вычисляется с использованием меры несходства между спектральными векторами типа векторных норм SAM (Spectral Angle Mapper [61]) и SID (Spectral Information Divergence [62]). Норма SAM определяет угол между векторами в пространстве признаков, а SID основана на сравнении векторов-признаков путём расчёта дивергенции Кульбака — Лейблера. Затем результирующая энергия минимизируется с применением теории графов [63] (рис. 7).

Несколько иной подход к учёту параметров соседних пикселей представлен в [64, 65]. Он также основан на вероятностной классификации и уточнении критериев близости пикселей к имеющимся классам по k ближайшим соседям (k NN — k -Nearest Neighbor), но соседи определяются не просто по их координатам в пространстве изображения, а по близости

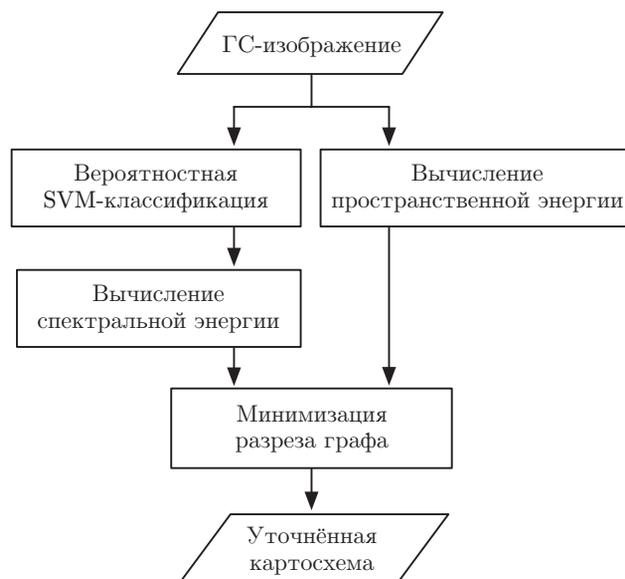


Рис. 7. Блок-схема метода классификации SVM с минимизацией энергии [60]



Рис. 8. Схема алгоритма классификации методом k ближайших соседей в сформированном пространстве признаков [65]

в пространстве признаков, сформированном из первой главной спектральной компоненты (PC1) изображения и нормированных пространственных координат каждого пикселя. Блок-схема данного алгоритма приведена на рис. 8.

Ещё один подобный метод постобработки основан на представлении изображения в виде графа и построении на этом графе минимального остовного леса (MSF — Minimum Spanning Forest) [66] в соответствии с картосхемой, полученной с помощью поэлементного классификатора [67].

Вершинами графа изображения являются пиксели изображения, а рёбра соединяют смежные пиксели. Вес ребра определяется по некоторой функции близости пикселей в пространстве спектральных признаков (например, спектрального угла или евклидова расстояния). Построенный граф берётся в качестве источника пространственной информации для уточнения картосхемы. С этой целью сначала выделяются маркёры каждого класса, в качестве которых используются связные области изображения, составленные из пикселей, классифицированных с высоким уровнем достоверности. Вершины графа, соответствующие этим пикселям, помечаются метками указанных классов. Далее в граф добавляются внешние вершины t_i , $i = 1, \dots, m$, где m — количество классов, и корневая вершина r . Помеченные вершины с индексом класса i соединяются виртуальными рёбрами нулевого веса с дополнительной вершиной t_i . Все вершины t_i в свою очередь рёбрами нулевого веса соединяются с корневой внешней вершиной r . После чего выполняется выделение минимального остовного дерева. После удаления виртуальных вершин дерево распадается на несвязанные компоненты (превращается в остовный лес). В каждой компоненте остаётся по одному маркёру, класс которого распространяется на всю компоненту.

На заключительном этапе полученная схема разделения изображения на сегменты и попиксельная картосхема используются совместно для уточнения картосхемы методом голосования пикселей (рис. 9). Для каждого сформированного сегмента выбирается класс как класс большинства пикселей в этом сегменте.

Чтобы обеспечить независимость результата от выбора маркёров, предлагается осуществлять их выбор случайным образом и применять ансамблевый подход. На каждой итерации ансамбля выбирается случайный набор маркёров, итоговая сегментация изображения строится на основе максимального голосования. При реализации данного алгоритма для построения минимального остовного дерева на модифицированном графе изображения используется классический алгоритм Крускала [68].

Для развития указанного метода в [69] предлагаются алгоритм, осуществляющий



Рис. 9. Блок-схема алгоритма классификации с использованием MSF [67]

попиксельную спектральную SVM-классификацию, и основанный на маркёрах MSF спектрально-пространственный алгоритм уточнения классов пикселей с низкой достоверностью классификации. При этом он применяется как бинарный классификатор, а в качестве разделяемых классов используются класс с низкой достоверностью классификации и оставшиеся классы. Отметим, что алгоритмы на основе MSF обладают существенно большей трудоёмкостью по сравнению с алгоритмами, использующими мажоритарный и вероятностный мажоритарный фильтры.

Эффективность различных методов классификации на основе предварительного формирования сегментов зависит в значительной степени от успешности выполнения этого этапа. Для снижения указанной зависимости в [70] предложен новый алгоритм спектрально-пространственной классификации, сочетающий в себе коллективный кластерный анализ [71] и обучение по сходству [72].

Идея предлагаемого подхода состоит в следующем. Процесс построения решающей функции делится на два основных этапа. На первом с помощью различных алгоритмов кластерного анализа по таблице данных строятся варианты группировки множества объектов и определяются индексы качества [70]. На базе полученных вариантов вычисляется усреднённая с весами коассоциативная матрица. Элементы матрицы равны средневзвешенной частоте отнесения пар объектов к одинаковым кластерам по всем вариантам разбиения, а веса зависят от оценочных функций (индексов качества). В определённом смысле матрица задаёт меры сходства объектов в новом признаковом пространстве, полученном из исходного с помощью некоторого преобразования. На втором этапе строится решающая функция с применением сформированной коассоциативной матрицы. В качестве такого алгоритма может выступать любой из известных, основанных на обучении по сходству или использовании ядра.

Привлечение коллектива алгоритмов кластерного анализа позволяет повысить устойчивость решений, более точно восстановить метрические отношения между объектами в условиях шумовых искажений и наличия сложных структур данных, что в конечном итоге повышает качество распознавания.

Методы на основе применения 3D-фильтров. Для одновременного учёта пространственной и спектральной информации в целом ряде работ предложено использовать трёхмерные преобразования для выделения спектрально-пространственных признаков. Ключевая идея состоит в спектрально-пространственном сглаживании 3D-массива ГС-данных на предварительном этапе и пространственном сглаживании сформированной в результате попиксельной классификации картосхемы классов для её уточнения на заключительном этапе.

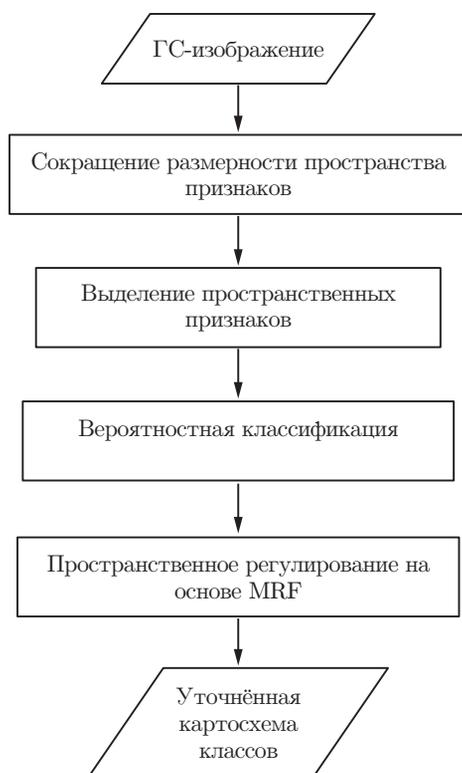


Рис. 10. Блок-схема алгоритма классификации с использованием $3D$ -фильтрации и постобработки картосхемы классов с учётом карт вероятности классификации [73]

Единая схема работы методов состоит из следующих этапов [73] (рис. 10):

- уменьшение размерности признаков;
- выделение спектрально-пространственных признаков с использованием $3D$ -ядер (например, $3D$ -вейвлетов);
- классификация методами попиксельной классификации с формированием картосхемы классов и карт вероятности;
- пространственное регулирование (например, на основе MRF);
- формирование уточнённой картосхемы классов.

В работе [73] эффективность метода продемонстрирована на нескольких примерах. В частности, на тестовом изображении [38] при использовании для обучения 15 % пикселей достигнута точность классификации 97 %. Аналогичная схема применяется в [74]. Здесь получена точность 81,12 %, но при существенно меньшем объёме обучающей выборки (по 15 пикселей на класс).

Большинство из рассматриваемых выше алгоритмов классификации основаны на выделении достаточно легко интерпретируемых признаков из набора регистрируемых данных на базе предварительных сведений о решаемых задачах. Однако с ростом объёмов получаемых данных это становится делать всё сложнее. Для решения задачи обнаружения в «сырых» данных ранее неизвестных, нетривиальных, но практически полезных и доступных интерпретации знаний, необходимых для классификации ГС-изображений, может быть эффективно использовано глубокое машинное обучение.

Технология глубокого обучения основана на искусственных нейронных сетях [75, 76]. В сравнении с обычным обучением глубокое обучение требует гораздо больше времени, ресурсов и объёмов данных. Однако в результате его использования осуществляется комплексный многоуровневый анализ всего набора данных для формирования иерархических

признаков (от нижнего уровня к верхнему). Применение таких технологий для классификации ГС-данных активно расширяется [77–85]. Так, в [81, 82] используются технологии свёрточных нейронных сетей (CNN — Convolutional Neural Network), где пространственные признаки формируются путём $2D$ -CNN модели с использованием нескольких первых главных компонент исходных ГС-данных.

В работах [83–85] предложен подход, основанный на применении $3D$ -CNN для классификации ГС-изображений. В частности, в [83] предлагается использовать полный набор спектральных полос в качестве входных данных без применения какой-либо предварительной или апостериорной обработки. Рис. 11 демонстрирует вычислительный процесс, который выполняется в три этапа:

Этап 1. Формируется обучающая выборка $3D$ -фрагментов размером $S \times S \times L$ из трёхмерного ГС-изображения с известными классами центральных пикселей этих фрагментов ($S \times S$ — пространственный размер фрагмента, L — количество спектральных полос).

Этап 2. Выполняется выделение глубоких спектрально-пространственных признаков, основанное на $3D$ -CNN. Каждый фрагмент размером $S \times S \times L$ подаётся на вход сети, в которой первый трёхмерный свёрточный уровень C1 содержит два $3D$ -ядра размером $K_1^1 \times K_2^1 \times K_3^1$. Каждое ядро образует один $3D$ -фрагмент преобразованных данных размером $(S - K_1^1 + 1) \times (S - K_2^1 + 1) \times (S - K_3^1 + 1)$. Второй трёхмерный свёрточный уровень включает четыре $3D$ -ядра размером $K_1^2 \times K_2^2 \times K_3^2$ и, получая на вход два $3D$ -фрагмента с выхода первого уровня, производит восемь $3D$ -фрагментов размером $(S - K_1^1 - K_1^2 + 2) \times (S - K_2^1 - K_2^2 + 2) \times (S - K_3^1 - K_3^2 + 2)$. Восемь $3D$ -кубов данных преобразуются в признаковый вектор, который подаётся на полносвязный уровень F1 с выходным вектором, содержащим окончательный спектрально-пространственный признак глубокого обучения.

Этап 3. Выполняется классификация, основанная на глубоких спектрально-пространственных признаках. Ошибка сети минимизируется с использованием алгоритма стохастического градиентного спуска с обратным распространением ошибки [86].

Экспериментальные результаты показывают, что предложенный подход превосходит по эффективности сравниваемые. В приведённых примерах $S = 5$, $K_1^1 = K_2^1 = K_3^1 = 3$, $K_1^2 = K_2^2 = K_3^2 = 3$. Утверждается, что данный алгоритм при обработке широко распространённого фрагмента тестового изображения, полученного в рамках программы AVIRIS на опытном полигоне «Индиан Пайнс» [38], позволил достичь точности 99,07 % (при обучающей выборке 50 % пикселей изображения).

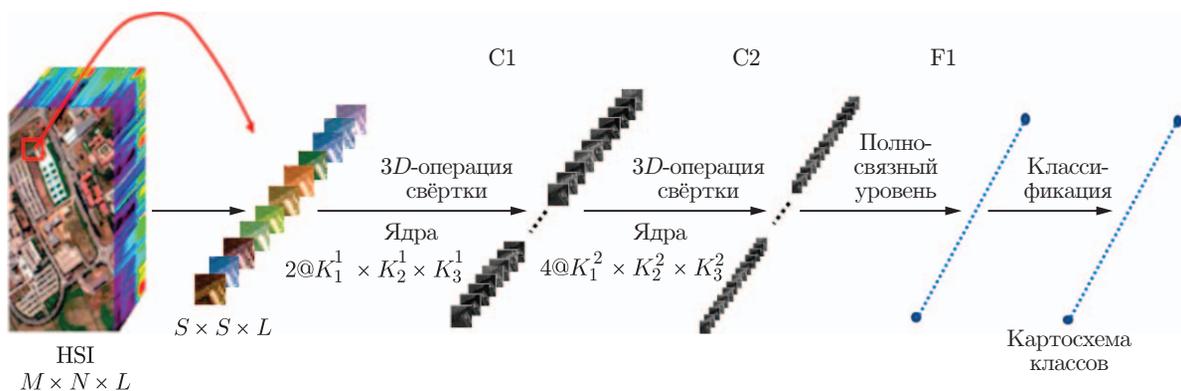


Рис. 11. Блок-схема алгоритма классификации на основе свёрточных нейронных сетей с глубоким обучением [83]



Рис. 12. Спектрально-пространственная классификация с включением в анализ информации о ближайшей окрестности на предварительном и заключительном этапах [88]

Экспериментальное исследование эффективности различных подходов.

В работах [87–92] исследована эффективность различных методов спектрально-пространственной классификации, учитывающих при анализе ГС-изображений локальные окрестности пикселей. В [87–91] рассмотрены алгоритмы, применяющие как пространственную предобработку исходных данных, так и постобработку картосхем попиксельной спектральной классификации путём выбора наиболее часто встречающегося класса (рис. 12). При этом в качестве анализируемой окрестности используется либо прямоугольное окно, либо сегменты, сформированные из наиболее близких по параметрам пикселей.

Так, в [88] рассмотрены следующие алгоритмы.

Алгоритм I. Выполняются уточнение значений пикселей исходного ГС-изображения путём двумерной медианной фильтрации по прямоугольному окну в каждом спектральном канале, а затем попиксельная спектральная классификация сформированного ГС-изображения.

Алгоритм II. Выполняется (основанное на выделении границ) разбиение изображения на однородные области с параметрами, обеспечивающими заведомо избыточное число сегментов. Далее определяются поканальные медианные значения внутри каждого сегмента и по полученным значениям осуществляется их попиксельная спектральная классификация.

Алгоритм III. Выполняются попиксельная спектральная классификация, а затем мажоритарная обработка [24] сформированной картосхемы с присвоением каждому пикселю номера класса, к которому принадлежит большая часть окружающих его пикселей. Таким образом определяется доминирующий класс в результате голосования пикселей по прямоугольному окну.

Алгоритм IV. Выполняются избыточная сегментация и независимо попиксельная спектральная классификация. Далее в сформированной картосхеме внутри каждого из сегментов находится наиболее часто встречающийся класс, номер которого присваивается всем его пикселям (класс устанавливается в результате голосования пикселей по сегменту).

Эффективность классификации определялась на примере обработки крупноформатного ГС-изображения (рис. 13), полученного в рамках программы AVIRIS на опытном полигоне «Индиан Пайнс» [38] путём сопоставления уточнённых картосхем классов, сформированных с применением перечисленных алгоритмов, и подспутниковых данных. В качестве

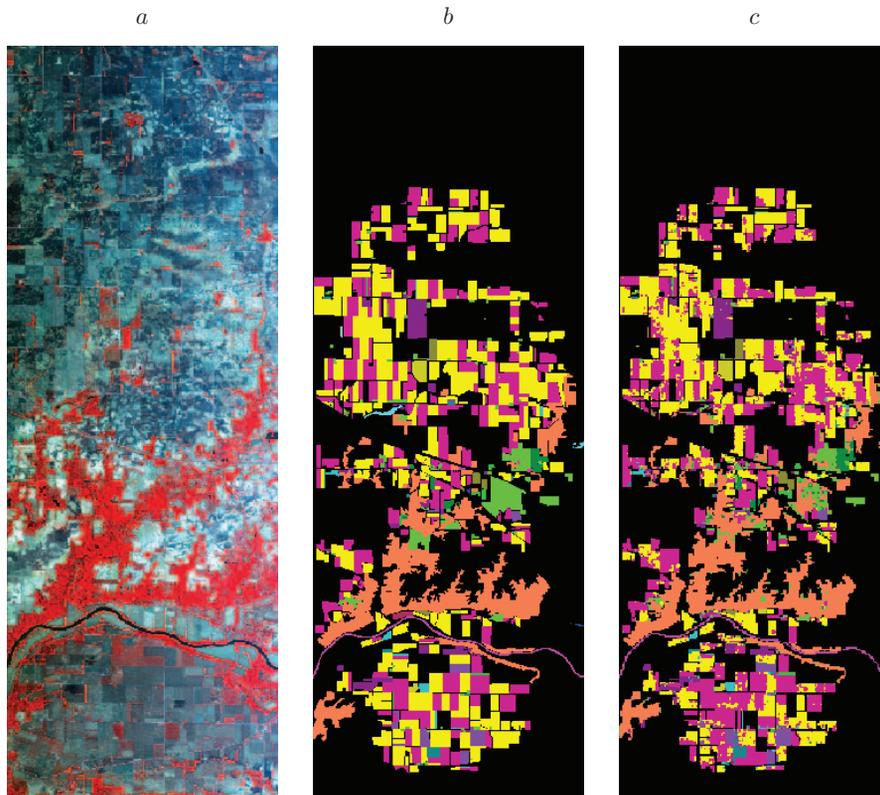


Рис. 13. Исходные данные: *a* — *RGB*-композит (каналы 40 : 20 : 10) крупноформатного ГС-изображения, *b* — эталонная карта классов изображения, *c* — результат спектрально-пространственной классификации [88]

критерия, как и ранее, использована результирующая точность классификации, определяемая как выраженное в процентах отношение количества верно классифицированных пикселей к их общему количеству.

Представленные данные показывают, что все рассматриваемые алгоритмы позволяют повысить точность классификации изображения. Большую результативность демонстрируют алгоритмы, основанные на сглаживании (уточнении значений пикселей) на этапе предварительной обработки по прямоугольным окнам. При обучающей выборке, сформированной из 25 % пикселей, точность спектральной классификации составила 72–76 % (в зависимости от количества признаков), с предварительным сглаживанием — 83–96 %, с постобработкой картосхем попиксельной классификации — 78–83 %.

Близкие значения получены в [89, 90] при классификации лесных пород по возрасту. В этих исследованиях сравнивались результаты традиционного попиксельного спектрального анализа, обработки с фильтрацией получаемой картосхемы с применением мажоритарной обработки и классификации с предварительным сглаживанием изображений (по окрестности и по сегментам). Установлено, что для анализируемых ГС-изображений учёт пространственной информации позволяет увеличить точность картосхем на 5–50 %, при этом лучшие результаты достигаются при предварительном усреднении по окрестности (в приведённом примере достигнута точность 100 %).

В [91] на примере фрагмента тестового изображения программы AVIRIS [38] показано, что включение окрестностей пикселей в анализ на любом этапе повышает точность классификации на 8–14 %, однако наибольшую эффективность демонстрируют методы предварительной обработки исходных данных (общая точность спектральной классифи-

кации составляет 80,72 %, с учётом предварительного пространственного сглаживания она достигает 94,46 %). При этом совместное применение пространственной обработки на начальном и завершающем этапах позволяет дополнительно увеличить точность на 1,0–1,5 %, а наибольшая результирующая точность была достигнута с помощью алгоритма, сочетающего предварительное сглаживание исходных данных и сглаживание карт вероятности классификации усредняющим фильтром Гаусса (95,91 %). Отметим, что указанные точности получены при малом объёме обучающей выборки (~6 % пикселей).

В [92] проведён сравнительный анализ эффективности спектральной и спектрально-пространственной классификаций типов растительности по ГС-данным при различных способах формирования обучающих выборок (случайным образом из всего изображения, по одной из его половин и по фрагментам, равномерно распределённым по изображению). На примере крупноформатного ГС-изображения (см. рис. 11) полигона «Индиан Пайнс» установлено, что результирующая точность при исследуемых способах обучения в значительной степени различается. Так, при формировании обучающей выборки из всего изображения достигнута точность классификации по 20 признакам 76,26 %, пространственная обработка позволила её повысить до 84,03 %. Точность классификации при обучении по части изображения оказалась ниже (не более 71,46 %), а применение предварительной пространственной обработки улучшило её лишь на 3–6 %.

При большем количестве признаков расхождение в результатах оказалось ещё более существенным. В случае 100 признаков для обучающей выборки, сформированной из всего изображения, точность классификации составила 76,60 %, а после предварительной пространственной обработки достигла 93,13 %, тогда как для выборок, сформированных из части изображения, она не превысила 71,54 % и при дополнительной пространственной обработке возросла не более чем на 6 %.

Фактически это означает, что при использовании большого количества спектрально-пространственных признаков возникает ситуация, близкая к переобучению. Хотя из обучающих выборок берётся только часть пикселей фрагмента, после осуществления процедуры предварительного сглаживания по ближайшим соседям в обучении участвует информация обо всех его пикселях (при формировании обучающих выборок более чем из 10 % пикселей). В результате такого обучения классификатору удаётся сформировать решающее правило, с высокой точностью разделяющее пиксели различных классов, если они принадлежат к тем же фрагментам, из которых выбирались пиксели для обучения. Однако эффективность классификации для других фрагментов оказывается значительно ниже.

Основными причинами невысокой точности классификации при обучении по части изображения (помимо схожести спектров отражения различных классов), по всей видимости, являются неполное устранение влияния неоднородности параметров регистрирующей системы по полю зрения, а также определённая внутриклассовая изменчивость характеристик растительности, связанная с локальными условиями её прорастания (состав почвы, влажность, высота, направление склона и т. п.).

Из этого следует, что для разделения трудноразличимых классов необходимо использовать обучающие выборки с максимальной степенью распределения пикселей по всему изображению. Однако такой подход на практике трудно реализуем, поскольку при решении большинства реальных задач невозможно обеспечить подспутниковые данные по всей наблюдаемой территории. Как правило, достоверные наземные данные имеются лишь для отдельных её участков и, следовательно, только по ним могут быть сформированы обучающие выборки. Поэтому исследования, ориентированные на оценку эффективности традиционных и оригинальных алгоритмов классификации ГС-изображений при обучении по всему полю наблюдения, следует признать недостаточно значимыми с точки зрения практических приложений.

Заключение. В последние два десятилетия развиты многочисленные подходы, направленные на повышение эффективности классификации ГС-изображений на основе интегрирования в процесс обработки пространственной информации. Указанная информация используется на предварительном этапе для извлечения текстурных и структурных характеристик изображений или, напротив, на этапе постобработки для уточнения полученных ранее результатов, в том числе с учётом сформированных карт вероятности классификации. Результаты многочисленных исследований показывают, что наибольшим потенциалом обладает первый подход, который заключается в том, что из одного ГС-изображения различными способами строится последовательность со всё более и более приближительным его описанием. Затем осуществляется попиксельная или посементная классификация полученного набора данных каким-либо традиционным методом. Такой подход в настоящее время активно развивается на основе инструментов многоградационной математической морфологии, однако, судя по публикациям, вполне удовлетворительные результаты могут быть достигнуты уже с использованием традиционных процедур сглаживания.

Логичным развитием указанных способов повышения эффективности классификации является также применение предварительной спектрально-пространственной обработки с использованием *3D*-ядер. Они соответствуют трёхмерной природе ГС-изображений и потенциально способны к более гибкой и точной их обработке.

Использование предварительной пространственной и спектрально-пространственной обработки ведёт к увеличению размерности пространства признаков. Поскольку ГС-данные имеют сотни спектральных каналов, после их обработки с применением нескольких *2D*- или *3D*-ядер количество признаков уже исчисляется тысячами. Прямое включение пространственных признаков в процедуру классификации приводит к высоким вычислительным затратам и, кроме того, требует больших объёмов обучающих выборок. Чтобы избежать указанных проблем, зачастую осуществляется сокращение числа исходных спектральных признаков, в частности с применением метода главных компонент. И хотя подобное снижение размерности пространства признаков используется достаточно часто, применять его следует аккуратно из-за возможных потерь полезной информации, особенно в задачах обнаружения объектов заданных классов.

В качестве альтернативного решения в настоящее время активно применяются методы, основанные на глубоком обучении свёрточных нейронных сетей. Такие сети способны обнаруживать в «сырых» данных ранее неизвестные, но практически полезные для классификации закономерности без участия оператора. Приводимые в публикациях, посвящённых этим методам, результаты экспериментальных исследований свидетельствуют об их исключительной эффективности. Однако не следует забывать, что в сравнении с обычным глубоким обучением требует гораздо больше времени, ресурсов и объёмов данных.

Развитие методов обработки и анализа ГС-данных существенно сдерживается недостаточным количеством имеющихся в свободном доступе крупноформатных изображений с сопутствующей подспутниковой информацией. Это значительно затрудняет объективную оценку эффективности предлагаемых методов их классификации, поскольку она может быть выполнена лишь на основе сопоставления результатов обработки реальных данных ДЗЗ и эталонных картосхем (подспутниковой информации).

СПИСОК ЛИТЕРАТУРЫ

1. **Перспективные** информационные технологии дистанционного зондирования Земли /Под ред. В. А. Сойфера. Самара: Новая техника, 2015. 256 с.
2. **Бондур В. Г.** Современные подходы к обработке больших потоков гиперспектральной и многоспектральной аэрокосмической информации // Исследование Земли из космоса. 2014. № 1. С. 4–16.

3. **Грузман И. С., Киричук В. С., Косых В. П. и др.** Цифровая обработка изображений в информационных системах: Учеб. пособие. Новосибирск: Изд-во НГТУ, 2002. 352 с.
4. **Бучнев А. А., Пяткин В. П.** Классификация с обучением гиперспектральных данных дистанционного зондирования Земли // Сб. матер. XIII Междунар. науч. конгресса «Интер-экспо Гео-Сибирь-2017». Новосибирск: СГГА, 2017. Т. 4. С. 8–12.
5. **Plaza A., Du Q., Bioucas-Dias J. M. et al.** Foreword to the special issue on spectral unmixing of remotely sensed data // IEEE Trans. Geosci. and Remote Sensing. 2011. **49**, N 11. P. 4103–4110.
6. **Козодеров В. В., Кондранин Т. В., Дмитриев Е. В.** Распознавание природно-техногенных объектов по гиперспектральным самолётным изображениям // Исследование Земли из космоса. 2014. № 1. С. 35–42.
7. **Асмус В. В., Бучнев А. А., Пяткин В. П.** Контролируемая классификация данных дистанционного зондирования Земли // Автометрия. 2008. **44**, № 4. С. 60–67.
8. **Kettig R. L., Landgrebe D. A.** Classification of multispectral image data by extraction and classification of homogeneous objects // IEEE Trans. Geosci. Electron. 1976. **GE-14**, N 1. P. 19–26.
9. **Scholz D., Russell J., Lindenlaub J., Swain P.** A case study using ECHO (extraction and classification of homogeneous objects) for analysis of multispectral scanner data // LARS Techn. Rep. 1977. Paper 105. 86 p.
10. **Benz U. C., Hofmann P., Willhauck G. et al.** Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information // ISPRS Journ. Photogram. and Remote Sensing. 2004. **58**, N 3–4. P. 239–258.
11. **Ryherd S., Woodcock C. E.** Combining spectral and texture data in the segmentation of remotely sensed images // Photogram. Eng. and Remote Sensing. 1996. **62**, N 2. P. 181–194.
12. **Huo L.-Z., Tang P.** Spectral and spatial classification of hyperspectral data using SVMs and Gabor textures // Proc. IEEE Intern. Geosci. and Remote Sensing Symposium (IGARSS 2011). Vancouver, Canada, 24–29 July, 2011. P. 1708–1711.
13. **Zhang L., Zhang L., Tao D., Huang X.** On combining multiple features for hyperspectral remote sensing image classification // IEEE Trans. Geosci. and Remote Sensing. 2012. **50**. P. 879–893.
14. **Chang C. C., Lin C. J.** LIBSVM: A library for support vector machines // ACM Trans. Intel. Syst. and Technol. 2011. **2**, N 3. P. 1–27.
15. **Chen C., Li W., Su H., Liu K.** Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine // Remote Sensing. 2014. **6**, N 6. P. 5795–5814. DOI: 10.3390/rs6065795.
16. **Plaza A., Martinez P., Perez R., Plaza J.** A new approach to mixed pixel classification of hyperspectral imagery based on extended morphological profiles // Pattern Recogn. 2004. **37**, N 6. P. 1097–1116.
17. **Benediktsson J. A., Palmason J. A., Sveinsson J. R.** Classification of hyperspectral data from urban areas based on extended morphological profiles // IEEE Trans. Geosci. and Remote Sensing. 2005. **43**, N 3. P. 480–491.
18. **Ghamisi P., Dalla Mura M., Benediktsson J. A.** A survey on spectral-spatial classification techniques based on attribute profiles // IEEE Trans. Geosci. and Remote Sensing. 2015. **53**, N 5. P. 2335–2353.
19. **Fauvel M., Chanussot J., Benediktsson J. A., Sveinsson J. R.** Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles // IEEE Trans. Geosci. and Remote Sensing. 2008. **46**, N 11. P. 3804–3814.

20. **Tuia D., Volpi M., Dalla Mura M. et al.** Automatic feature learning for spatio-spectral image classification with sparse SVM // *IEEE Trans. Geosci. and Remote Sensing*. 2014. **52**, N 10. P. 6062–6074.
21. **Dalla Mura M., Villa A., Benediktsson J. A. et al.** Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis // *IEEE Geosci. and Remote Sensing Lett.* 2011. **8**, N 3. P. 542–546.
22. **Gormus E. T., Canagarajah N., Achim A.** Dimensionality reduction of hyperspectral images with wavelet based empirical mode decomposition // *Proc. of the 18th IEEE Intern. Conf. on Image Processing*. Brussels, Belgium, 11–14 Sept., 2011. P. 1709–1712.
23. **Нежевенко Е. С., Феоктистов А. С., Дашевский О. Ю.** Нейросетевая классификация гиперспектральных изображений на основе преобразования Гильберта — Хуанга // *Автометрия*. 2017. **53**, № 2. С. 79–85.
24. **Lillesand T. M., Kiefer R. W., Chipman J. W.** *Remote Sensing and Image Interpretation*. N. Y.: John Wiley & Sons, 2004. 763 p.
25. **Hader D. P.** *Image Analysis: Methods and Applications*. London: CRC Press, 2000. 480 p.
26. **Qian Y., Ye M., Zhou J.** Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features // *IEEE Trans. Geosci. and Remote Sensing*. 2013. **51**, N 4. P. 2276–2291.
27. **Bau T. C., Sarkar S., Healey G.** Hyperspectral region classification using a three-dimensional Gabor filterbank // *IEEE Trans. Geosci. and Remote Sensing*. 2010. **48**, N 9. P. 3457–3464.
28. **Shen L., Jia S.** Three-dimensional Gabor wavelets for pixel-based hyperspectral imagery classification // *IEEE Trans. Geosci. and Remote Sensing*. 2011. **49**, N 12. P. 5039–5046.
29. **Tang Y., Lu Y., Yuan H.** Hyperspectral image classification based on three-dimensional scattering wavelet transform // *IEEE Trans. Geosci. and Remote Sensing*. 2015. **53**, N 5. P. 2467–2480.
30. **Chen C., Li W., Tramel E. W. et al.** Spectral-spatial preprocessing using multihypothesis prediction for noise-robust hyperspectral image classification // *IEEE Journ. Sel. Top. Appl. Earth Observ. Remote Sensing*. 2014. **7**, Is. 4. P. 1047–1059.
31. **Palsson F., Ulfarsson M., Sveinsson J. R.** Hyperspectral image denoising using a sparse low rank model and dual-tree complex wavelet transform // *Proc. IEEE Intern. Conf. on Geosci. and Remote Sensing*. Quebec, Canada, 13–18 July, 2014. P. 3670–3673.
32. **Zhen Y., Mingyi H., Fowler J. E., Qian D.** Hyperspectral image classification based on spectra derivative features and locality preserving analysis // *Proc. of the Signal and Information Processing (ChinaSIP), IEEE China Summit & Intern. Conf. Xi'an, China, 9–13 July, 2014*. P. 138–142.
33. **Тихонов А. Н., Арсенин В. Я.** *Методы решения некорректных задач*. М.: Наука, 1979. 286 с.
34. **Cristianini N., Shawe-Taylor J.** *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. Cambridge: Cambridge University Press, 2000. 189 p.
35. **Huang G.-B., Zhu Q.-Y., Siew C.-K.** *Extreme learning machine: Theory and applications* // *Neurocomputing*. 2006. **70**. P. 489–501.
36. **Huang G.-B., Chen L., Siew C.-K.** Universal approximation using incremental constructive feedforward networks with random hidden nodes // *IEEE Trans. Neural Networks*. 2006. **17**, N 4. P. 879–892.
37. **Huang N. E., Shen Z., Long S. R. et al.** The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis // *Proc. Royal Soc. London. Ser. A*. 1998. **454**, Is. 1971. P. 903–995.

38. **Baumgardner M. F., Biehl L. L., Landgrebe D. A.** 220 Band AVIRIS Hyperspectral Image Data Set: June 12, 1992. Indian Pine Test Site 3. Purdue University Research Repository. 2015. DOI: 10.4231/R7RX991C.
39. **Pesaresi M., Benediktsson J. A.** A new approach for the morphological segmentation of high-resolution satellite imagery // *IEEE Trans. Geosci. and Remote Sensing*. 2001. **39**, N 2. P. 309–320.
40. **Soille P.** *Morphological Image Analysis, Principles and Applications*. Berlin: Springer Verlag, 2003. 391 p.
41. **Zhu C., Shi W., Pesaresi M. et al.** The recognition of road network from high-resolution satellite remotely sensed data using image morphological characteristics // *Intern. Journ. Remote Sensing*. 2005. **26**, N 24. P. 5493–5508.
42. **Breen E. J., Jones R.** Attribute openings, thinnings, and granulometries // *Computer Visual and Image Understanding*. 1996. **64**, N 3. P. 377–389.
43. **Dalla Mura M., Benediktsson J. A., Waske B., Bruzzone L.** Morphological attribute filters for the analysis of very high resolution images // *Proc. IEEE Intern. Geosci. and Remote Sensing Symposium (IGARSS 2009)*. Cape Town, South Africa, 13–17 July, 2009. P. 97–100.
44. **Dalla Mura M., Benediktsson J. A., Waske B., Bruzzone L.** Morphological attribute profiles for the analysis of very high resolution images // *IEEE Trans. Geosci. and Remote Sensing*. 2010. **48**, N 10. P. 3747–3762.
45. **Joelsson S. R., Benediktsson J. A., Sveinsson J. R.** Random forest classifiers for hyperspectral data // *Proc. IEEE Intern. Geosci. and Remote Sensing Symposium (IGARSS 2005)*. Seoul, Korea, 25–29 July, 2005. Vol. 1–8. P. 160–163.
46. **Dalla Mura M., Benediktsson J. A., Waske B., Bruzzone L.** Extended profiles with morphological attribute filters for the analysis of hyperspectral data // *Intern. Journ. Remote Sensing*. 2010. **31**, N 22. P. 5975–5991.
47. **Aptoula E.** Hyperspectral image classification with multidimensional attribute profiles // *IEEE Geosci. and Remote Sensing Lett.* 2015. **12**, N 10. P. 2031–2035.
48. **Pham M.-T., Aptoula E., Lefèvre S.** Feature profiles from attribute filtering for classification of remote sensing images // *IEEE Journ. Sel. Top. Appl. Earth Observ. Remote Sensing*. 2018. **11**, N 1. P. 249–256. DOI: 10.1109/JSTARS.2017.2773367.
49. **Demir B., Bruzzone L.** Histogram-based attribute profiles for classification of very high resolution remote sensing images // *IEEE Trans. Geosci. and Remote Sensing*. 2016. **54**, N 4. P. 2096–2107.
50. **Battiti R., Demir B., Bruzzone L.** Compressed histogram attribute profiles for the classification of VHR remote sensing images // *Proc. SPIE*. 2015. **9643**. 96430R.
51. **Pham M.-T., Lefèvre S., Aptoula E.** Local feature-based attribute profiles for optical remote sensing image classification // *IEEE Trans. Geosci. and Remote Sensing*. 2018. **56**, N 2. P. 1199–1212.
52. **Pham M.-T., Lefèvre S., Aptoula E., Damodaran B. B.** Classification of VHR remote sensing images using local feature-based attribute profiles // *Proc. IEEE Intern. Geosci. and Remote Sensing Symposium (IGARSS 2011)*. Texas, USA, 23–28 July, 2017. P. 1083–1086.
53. **Aptoula E., Ozdemir M. C., Yanikoglu B.** Deep learning with attribute profiles for hyperspectral image classification // *IEEE Geosci. and Remote Sensing Lett.* 2016. **13**, N 12. P. 1970–1974.
54. **Sun B., Kang X., Li S., Benediktsson J. A.** Random-walker-based collaborative learning for hyperspectral image classification // *IEEE Trans. Geosci. and Remote Sensing*. 2017. **55**, N 1. P. 212–222.

55. **Sun B., Kang X., Li S., Benediktsson J. A., Bruzzone L.** Recent developments from attribute profiles for remote sensing image classification // Proc. of the Intern. Conf. on Pattern Recognition and Artificial Intelligence. Montreal, Canada, 14–17 May, 2018. arXiv: 1803.10036V1. URL: <https://arxiv.org/pdf/1803.10036.pdf> (дата обращения: 08.12.2016).
56. **Зимичев Е. А., Казанский Н. Л., Серафимович П. Г.** Пространственная классификация гиперспектральных изображений с использованием метода кластеризации K-MEANS++ // Компьютерная оптика. 2014. **38**, № 2. С. 281–286.
57. **Борзов С. М., Мельников П. В., Пестунов И. А. и др.** Комплексная обработка гиперспектральных изображений на основе спектральной и пространственной информации // Вычислительные технологии. 2016. **21**, № 1. С. 25–39.
58. **Borhani M., Ghassemian H.** Hyperspectral image classification based on spectral-spatial features using probabilistic SVM and locally weighted Markov random fields // Proc. of the Iranian Conf. on Intelligent Systems (ICIS 2014). Bam, Iran, 4–6 Feb., 2014. P. 1–6.
59. **Hu Y., Saber E., Monteiro S. T. et al.** Classification of hyperspectral images based on conditional random fields // Proc. SPIE. 2015. **9405**. 940510. URL: <http://dx.doi.org/10.1117/12.2083374> (дата обращения: 10.09.2018).
60. **Tarabalka Y., Rana A.** Graph-cut-based model for spectral-spatial classification of hyperspectral images // Proc. IEEE Intern. Geosci. and Remote Sensing Symposium (IGARSS 2014). Quebec, Canada, 13–18 July, 2014. P. 3418–3421.
61. **Kruse F. A., Lefkoff A. B., Boardman J. W. et al.** The spectral image processing system (SIPS) — Interactive visualization and analysis of imaging spectrometer data // Remote Sensing of Environment. 1993. **44**, Is. 2–3. P. 145–163.
62. **Du H., Chang C., Ren H. et al.** New hyperspectral discrimination measure for spectral characterization // Opt. Eng. 2004. **43**, N 8. P. 1777–1786.
63. **Boykov Y., Veksler O., Zabih R.** Fast approximate energy minimization via graph cuts // IEEE Trans. Pattern Anal. and Mach. Intell. 2001. **23**, N 11. P. 1222–1239.
64. **Huang K., Li S., Kang X., Fang L.** Spectral-spatial hyperspectral image classification based on KNN // Sens. and Imaging. 2016. **17**, N 1. URL: <https://doi.org/10.1007/s11220-015-0126-z> (дата обращения: 10.09.2018).
65. **Song W., Li S., Kang X., Huang K.** Hyperspectral image classification based on KNN sparse representation // Proc. of IEEE Intern. Geosci. and Remote Sensing Symposium (IGARSS 2016). Beijing, China, 10–15 July, 2016. P. 2411–2414.
66. **Tarabalka Y., Chanussot J., Benediktsson J. A.** Segmentation and classification of hyperspectral images using minimum spanning forest grown from automatically selected markers // IEEE Trans. Syst., Man and Cybern. Pt. B: Cybernetics. 2010. **40**, N 5. P. 1267–1279.
67. **Stawiaski J.-F.** Mathematical Morphology and Graphs: Application to Interactive Medical Image Segmentation: Ph. D. Thesis. Paris, France: Paris School of Mines, 2008. 175 p.
68. **Кормен Т. Х., Лейзерсон Ч. И., Ривест Р. Л., Штайн К.** Алгоритмы: построение и анализ. М.: Издательский дом «Вильямс», 2010. 1296 с.
69. **Akbari D.** A new spectral-spatial framework for classification of hyperspectral data // Intern. Arch. Photogramm. Remote Sensing Spatial Inform. Sci. 2017. Vol. XLII-4/W5. P. 7–10. URL: <https://doi.org/10.5194/isprs-archives-XLII-4-W5-7-2017> (дата обращения: 10.09.2018).
70. **Бериков В. Б., Пестунов И. А., Караев Н. М., Тевари А.** Распознавание гиперспектральных изображений с использованием кластерного ансамбля и частично контролируемого обучения // Тр. Всерос. конф. «Обработка пространственных данных в задачах мониторинга природных и антропогенных процессов (SDM-2017)». Новосибирск: ИБТ СО РАН, 2017. С. 60–64. URL: [http://conf.nsc.ru/files/conferences/SDM-2017/427493/\(SDM-2017\)%20Thesis.pdf](http://conf.nsc.ru/files/conferences/SDM-2017/427493/(SDM-2017)%20Thesis.pdf) (дата обращения: 10.09.2018).

71. **Berikov V., Pestunov I.** Ensemble clustering based on weighted co-association matrices: Error bound and convergence properties // *Pattern Recogn.* 2017. **63**, Is. C. P. 427–436.
72. **Shawe-Taylor J., Cristianini N.** *Kernel Methods for Pattern Analysis.* N. Y.: Cambridge University Press, 2004. 462 p.
73. **AbdelFattah M., AbdelAal L. F., El-khoribi R.** Spectral-spatial hyperspectral image classification based on randomized singular value decomposition and 3-dimensional discrete wavelet transform // *Intern. Journ. Comput. Appl. (0975–8887).* 2018. **180**, N 30. P. 1–10. URL: file:///C:/Documents%20and%20Settings/bs/%D0%9C%D0%BE%D0%B8%20%D0%B4%D0%BE%D0%BA%D1%83%D0%BC%D0%B5%D0%BD%D%82%D1%8B/Downloads/Spectral-Spatial_Hyperspectral_Image_Classificatio.pdf (дата обращения: 10.09.2018).
74. **Caо X., Xu L., Meng D. et al.** Integration of 3-dimensional discrete wavelet transform and Markov random field for hyperspectral image classification // *Neurocomputing.* 2017. **226**. P. 90–100. URL: <http://dx.doi.org/10.1016/j.neucom.2016.11.034> (дата обращения: 10.09.2018).
75. **Гудфеллоу Я., Бенджио И., Курвилль А.** *Глубокое обучение.* М.: ДМК Пресс, 2017. 652 с.
76. **Николенко С., Кадурин А., Архангельская Е.** *Глубокое обучение. Погружение в мир нейронных сетей.* С.-Пб.: Питер, 2018. 480 с.
77. **Zhang L., Zhang L., Du B.** Deep learning for remote sensing data: A technical tutorial on the state of the art // *IEEE Geosci. Remote Sensing Mag.* 2016. **4**, N 2. P. 22–40.
78. **Chen Y., Lin Z., Zhao X., Wang G.** Deep learning-based classification of hyperspectral data // *IEEE Journ. Sel. Top. Appl. Earth Observ. Remote Sensing.* 2014. **7**, N 6. P. 2094–2107.
79. **Li T., Zhang J., Zhang Y.** Classification of hyperspectral image based on deep belief networks // *Proc. of the IEEE Intern. Conf. on Image Processing.* Paris, France, 27–30 Oct., 2014. P. 5132–5136.
80. **Chen Y., Zhao X., Jia X.** Spectral-spatial classification of hyperspectral data based on deep belief network // *IEEE Journ. Sel. Top. Appl. Earth Observ. Remote Sensing.* 2015. **8**, N 6. P. 2381–2392.
81. **Zhao W., Du S.** Spectral-spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach // *IEEE Trans. Geosci. and Remote Sensing.* 2016. **54**, N 8. P. 4544–4554.
82. **Yue J., Zhao W., Mao S., Liu H.** Spectral-spatial classification of hyperspectral images using deep convolutional neural networks // *Remote Sensing Lett.* 2015. **6**, N 6. P. 468–477.
83. **Li Y., Zhang H., Shen Q.** Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network // *Remote Sensing.* 2017. **9**, N 1. 67. DOI: 10.3390/rs9010067.
84. **Makantasis K., Karantzalos K., Doulamis A., Doulamis N.** Deep supervised learning for hyperspectral data classification through convolutional neural networks // *Proc. of the IEEE Intern. Geosci. and Remote Sensing Symposium (IGARSS 2015).* Milan, Italy, 26–31 July, 2015. P. 4959–4962.
85. **Wei W., Zhang J., Zhang L. et al.** Deep cube-pair network for hyperspectral imagery classification // *Remote Sensing.* 2018. **10**, N 5. 783. DOI: 10.3390/rs10050783.
86. **Simonyan K., Zisserman A.** Very deep convolutional networks for large-scale image recognition // *Proc. of the Intern. Conf. on Learning Representations.* San Diego, USA, 7–9 May, 2015. URL: <https://arxiv.org/pdf/1409.1556> (дата обращения: 10.09.2018).
87. **Борзов С. М., Потатуркин А. О., Потатуркин О. И., Федотов А. М.** Исследование эффективности классификации гиперспектральных спутниковых изображений природных и антропогенных территорий // *Автометрия.* 2016. **52**, № 1. С. 3–14.

88. **Борзов С. М., Потатуркин О. И.** Исследование эффективности спектрально-пространственной классификации данных гиперспектральных наблюдений // *Автометрия*. 2017. **53**, № 1. С. 32–42.
89. **Melnikov P. V., Pestunov I. A., Rylov S. A.** Comparison of spectral-spatial classification methods for hyperspectral images of high spatial resolution // *Journ. Siberian Federal University. Eng. & Technol.* 2017. **10**, Is. 6. P. 805–811. DOI: 10.17516/1999-494X-2017-10-6-805-811.
90. **Мельников П. В., Пестунов И. А., Рылов С. А.** Экспериментальное сравнение методов классификации гиперспектральных изображений высокого пространственного разрешения по спектральным и пространственным признакам // *Сб. мат. III Междунар. науч. конф. «Региональные проблемы дистанционного зондирования Земли»*. Красноярск: СФУ, 2016. С. 28–33.
91. **Гурьянов М. А., Борзов С. М.** Спектрально-пространственная классификация типов растительности по гиперспектральным данным // *Вестн. НГУ. Сер. Информационные технологии*. 2017. **15**, № 4. С. 14–21.
92. **Борзов С. М., Потатуркин О. И.** Классификация гиперспектральных изображений при различных способах формирования обучающих выборок // *Автометрия*. 2018. **54**, № 1. С. 89–97.

Поступила в редакцию 10 сентября 2018 г.
