

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 528.72 : 004.93

КЛАССИФИКАЦИЯ ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ ПРИ РАЗЛИЧНЫХ СПОСОБАХ ФОРМИРОВАНИЯ ОБУЧАЮЩИХ ВЫБОРОК*

С. М. Борзов¹, О. И. Потатуркин^{1,2}

¹Институт автоматизации и электрометрии СО РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 1

²Новосибирский государственный университет,
630090, г. Новосибирск, ул. Пирогова, 2

E-mail: borzov@iae.nsk.su
potaturkin@iae.nsk.su

Проведены исследования эффективности методов контролируемых спектральной и спектрально-пространственной классификаций типов растительности по данным гиперспектральной съёмки при различных способах формирования обучающих выборок. Рассмотрены зависимости точности классификации от количества спектральных признаков. Показано, что одновременный учёт пространственных и спектральных признаков позволяет достичь качественной классификации трудноразличимых типов растительности только при использовании обучающих выборок с максимальной степенью распределения пикселей по изображению.

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

DOI: 10.15372/AUT20180112

Введение. В последнее десятилетие при дистанционном зондировании Земли (ДЗЗ) всё чаще рассматривается возможность использования технологий гиперспектральной (ГС) съёмки в видимом и инфракрасном диапазонах [1]. Регистрируемые при такой съёмке данные отличаются узкой шириной и большим количеством спектральных каналов, что позволяет осуществлять анализ тонкой структуры спектров отражения объектов и потенциально открывает возможности к их более детальной классификации. В то же время несмотря на запуски ряда космических аппаратов с ГС-сканерами и активное развитие авиационных проектов, таких как программа AVIRIS (Airborne Visible Infrared Imaging Spectrometer), перспективы применения гиперспектральных данных по-прежнему не в полной мере ясны. Их ценность по сравнению с обычными мультиспектральными остаётся под вопросом, особенно если учесть затраты, необходимые на регистрирующее оборудование, а также передачу, обработку и хранение гигантского объёма поступающей информации.

Использование ГС-данных оправдано в задачах, которые не могут быть решены средствами многозональной съёмки, в частности, при классификации подклассов поверхности, отличающихся не только типом материала, но и его состоянием. Однако для этого необходимо совершенствование соответствующих технологий обработки регистрируемых многомерных данных в целях учёта их всевозможных искажений и межклассового и внутриклассового разнообразия. Так, применяется подход, основанный на сокращении объёма данных при решении конкретных прикладных задач путём выбора наиболее информа-

*Работа выполнена при финансовой поддержке Президиума РАН (комплексная программа фундаментальных исследований Сибирского отделения РАН, проекты № П.1.37, № П.1.49) и Федерального агентства научных организаций (проект № 0319-2018-0008, № государственной регистрации АААА-А17-117052410034-6).

тивных спектральных каналов и подсистем признаков [2, 3]. В работах [4, 5] на примере анализа реальных ГС-изображений показано, что эффективность классификации типов растительности практически не снижается при сокращении количества признаков в 20 раз (при правильном их выборе). Очевидно, что методика формирования системы информативных признаков для каждой задачи мониторинга поверхности Земли представляет собой отдельную серьёзную проблему.

Дополнительное повышение достоверности классификации может быть достигнуто при одновременном анализе спектральных и пространственных признаков [6–9], для чего применяются два подхода. Первый использует предварительную пространственную обработку изображений в целях уточнения значения каждого пикселя с учётом значений пикселей в его локальной окрестности и последующую спектральную классификацию полученных данных [10, 11]. Второй заключается в первоначальной попиксельной спектральной классификации и последующей пространственной обработке сформированных картосхем с отнесением каждого пикселя к наиболее часто встречающемуся классу в его окрестности [12, 13].

Достоверную оценку эффективности методов классификации ГС-изображений можно получить лишь на основе сопоставления результатов обработки реальных данных ДЗЗ и карт наземных (подспутниковых) наблюдений — эталонных картосхем. Во многих работах подобные исследования осуществляются на небольших тестовых фрагментах [14–18]. При этом в качестве обучающей выборки (ОВ) используется случайный набор пикселей каждого класса, а в качестве тестовой — все оставшиеся. Такой подход позволяет оперативно получить требуемую оценку, однако её объективность вызывает определённые сомнения. В первую очередь это связано с малым объёмом обучающих выборок, а также со сложностью способа их формирования в практических применениях.

Целью данной работы является экспериментальное исследование эффективности методов спектральной и спектрально-пространственной классификаций типов растительности по крупноформатным гиперспектральным изображениям в зависимости от количества учитываемых спектральных признаков и способа формирования ОВ. При этом точность классификации оценивается путём сопоставления подспутниковых данных и картосхем классов, сформированных сравниваемыми методами.

Исходные данные. Предлагаемая работа является продолжением исследований, начатых в [19, 20], где на примере обработки крупноформатного ГС-изображения, полученного в рамках программы AVIRIS на опытном полигоне «Индиан Пайнс» (штат Индиана, США) [21], экспериментально сравнивается эффективность ряда методов спектральной и спектрально-пространственной классификаций трудноразличимых типов растительности. Обучение при этом проводилось с использованием одного из фрагментов размером 145×145 пикселей и набора пикселей, сформированного путём случайного выбора из всего изображения. Показано, что лучшие результаты достигаются с применением методов опорных векторов (SVM) [22, 23] и максимального правдоподобия (ML) [24], а для анализа целесообразно использовать небольшое количество спектральных признаков (10–20), выделенных методом главных компонент с нормализацией шума каналов (метод MNF) [25]. Продемонстрировано, что одновременный анализ спектральных и пространственных признаков позволяет снизить раздробленность результирующих картосхем, при этом учёт пространственной информации целесообразно осуществлять на этапе предварительной обработки изображений.

В предлагаемой работе исследование эффективности методов классификации данных ДЗЗ, как и в [19, 20], проводилось на примере обработки вышеуказанного крупноформатного ГС-изображения. Его размер составил 614×2677 пикселей, разрешение — 20 м/пиксель, число каналов — 220 в диапазоне 0,4–2,5 мкм, при этом 20 каналов, содержащих высокий уровень шума, при проведении исследований не рассматриваются. По результатам



Рис. 1. Всходы кукурузы (регион Corn no-till) [21]

наземных наблюдений выполнено разбиение данного изображения на 58 классов, в том числе 15 классов кукурузы и 18 сои, отличающихся способами производства. В частности, имеются участки с различными методиками возделывания почвы: no-till — вспашка не производится, min-till — вспашка с применением малоразрушающих технологий, clear — обычная вспашка, а отдельные из них отличаются лишь направлением посева (север—юг или запад—восток). Общее количество пикселей в разбитой на классы части изображения 334245, из них 128719 (39 %) — различные классы кукурузы, 91770 (27 %) — сои, 63706 (19 %) — лес, 15 % пикселей относятся к прочим 24 классам. Часть территории не размечена и в данной работе не рассматривается.

Сравнение картосхемы наземных наблюдений с ГС-изображением показывает, что она значительно обобщена. Многочисленные небольшие особенности, визуально различимые на изображении, на ней не отмечены. Кроме того, из-за ранней даты регистрации изображения (12 июня) на ряде участков всходы соответствующей растительности составляют только малый процент покрытия. Область, отмеченная на карте как Corn no-till, в действительности содержит по большей части участки голой почвы и остатки прошлогодней растительности (рис. 1). Таким образом, не следует ожидать, что каждый пиксель определённой области будет отнесён к классу, с ней связанному.

Можно также отметить значительную спектральную изменчивость отдельных культур на различных участках изображения. Так, классы кукурузы и сои имеют близкие спектральные характеристики, однако внутри каждого из них наблюдается существенный разброс значений. Среднеквадратичное отклонение спектральных коэффициентов отражения в наиболее информативных диапазонах превышает разброс средних значений для классов [4].

Классификация типов подстилающей поверхности при различных способах формирования обучающих выборок. В данной работе сравнивается эффективность методов спектрально-пространственной классификации ГС-изображений, учитывающих локальные окрестности пикселей, при различных способах формирования ОБ. Рассматриваются алгоритмы, использующие как предварительное пространственное усреднение исходных данных (далее алгоритм I), так и постобработку картосхем попиксельной спектральной классификации (далее алгоритм II).

При реализации алгоритма I на первом этапе выполняется уточнение векторов признаков, характеризующих пиксели ГС-изображения, путём двумерной медианной фильтрации по прямоугольному окну в каждом спектральном канале, а на втором — попиксельная спектральная классификация сформированных данных. При реализации алгоритма II на первом этапе выполняется попиксельная спектральная классификация ГС-изображения, а на втором — мажоритарная обработка сформированной картосхемы с присвоением каждому пикселю номера класса, к которому принадлежит большая часть окружающих его пикселей.

Для спектральной классификации используются методы SVM и ML (как показано в [19], они обеспечивают лучшую точность классификации указанного изображения). При этом для формирования наиболее значимых спектральных признаков применяется метод MNF. Обе процедуры пространственной обработки выполняются скользящим окном размером 7×7 пикселей (в [20] показано, что данный размер окна обеспечил лучшие результаты в экспериментальных исследованиях с фрагментом указанного изображения).

Исследование алгоритмов выполняется при трёх различных способах формирования обучающей выборки из крупноформатного ГС-изображения с учётом информации о принадлежности пикселей к классам:

- случайным образом выбирается по 25 % пикселей из всего изображения (ОВ1);
- случайным образом выбирается 50 % пикселей из левой половины изображения (ОВ2);
- случайным образом выбирается 50 % пикселей шахматных клеток одного цвета (ОВ3).

Отметим, что объёмы обучающих выборок во всех случаях приблизительно равны. Незначительное их отличие связано с неравномерным распределением классов по изображению и с необходимостью исключения из рассмотрения тех из них, пиксели которых оказываются представленными в ОВ в недостаточном количестве. В качестве тестовой выборки в первом случае используются все пиксели ГС-изображения, не вошедшие в ОВ1, во втором и третьем — пиксели областей, неиспользованных для формирования ОВ2 и ОВ3 соответственно. На рис. 2, *a, b* показаны картосхемы обучающих выборок из части изображения.

Оценка эффективности классификации выполняется путём сопоставления сформированных картосхем классов и подспутниковых данных. В качестве критерия используется так называемая результирующая точность классификации, определяемая как выраженное в процентах отношение количества верно классифицированных пикселей к их общему количеству в тестовой выборке. При этом точность классификации рассчитывается по 27




Рис. 2. Картосхемы обучающих выборок, сформированных по части изображения: *a* — ОВ2, *b* — ОВ3

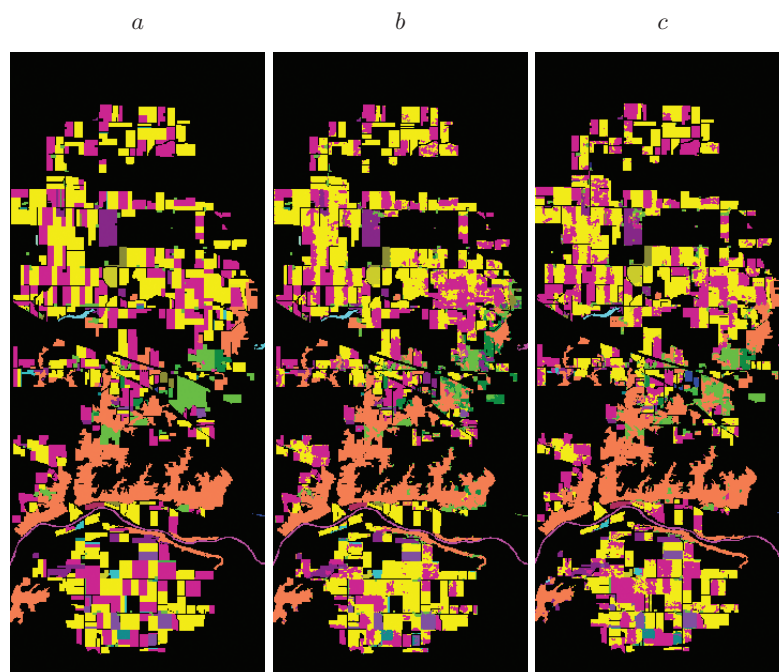


Рис. 3. Классификация крупноформатного ГС-изображения: *a* — эталонная карто-схема классов; *b, c* — результирующие картосхемы классов для OB2 и OB3

основным классам (с объединением 15 подклассов кукурузы и 18 сои в классы кукурузы и сои в результирующей картосхеме).

На рис. 3 представлены картосхемы при классификации методом SVM по 20 MNF-признакам с предварительной пространственной обработкой — медианной фильтрацией (алгоритм I). Точность классификации в данном случае составляет 67,01 % (рис. 3, *b*) и 77,13 % (рис. 3, *c*).

Численные значения точности спектральной и спектрально-пространственной классификаций крупноформатного ГС-изображения при различных ОБ вышепредставленными методами при использовании 20 и 100 MNF-признаков приведены в таблице.

Видно, что при ОБ1, сформированной случайным образом из всего изображения, бóльшую результативность обеспечивает алгоритм I, основанный на предварительном сглаживании. Так, при 20 признаках он позволяет повысить точность классификации относительно соответствующей спектральной на 7–12 %, а при 100 признаках — на 20 % и более. В то же время алгоритм II, основанный на постобработке картосхем попиксельной классификации, для 20 признаков приводит к увеличению точности лишь на 2 %, а для 100 — от 2 до 5 %. При ОБ, сформированных случайным образом из части ГС-изображе-

Алгоритмы классификации	SVM			ML		
	OB1	OB2	OB3	OB1	OB2	OB3
Спектральная классификация (20 MNF)	76,26	63,96	71,64	72,46	56,79	66,19
Спектральная классификация (100 MNF)	76,24	64,58	71,54	76,60	58,04	68,35
С предварительным сглаживанием (I) (20 MNF)	83,96	67,01	77,13	84,03	59,16	73,70
С предварительным сглаживанием (I) (100 MNF)	85,98	67,82	70,53	93,13	59,36	72,23
С постобработкой голосованием (II) (20 MNF)	78,92	66,47	75,21	77,17	60,13	69,77
С постобработкой голосованием (II) (100 MNF)	79,65	66,48	75,53	83,55	62,27	74,50




Рис. 4. Точность спектральной (0) и спектрально-пространственной (1, 2 для алгоритмов I, II соответственно) классификаций методом ML при различных обучающих выборках: *a* — 20 MNF-признаков, *b* — 100 MNF-признаков

ния, эффективности обоих алгоритмов близки (точность повышается не более чем на 6 %).

Отметим, что из двух используемых способов построения обучающей выборки из части изображения более эффективным оказывается способ, применяющий шахматные клетки — OB3 (рис. 4). Он более точно характеризует параметры каждого класса на всём изображении, поскольку в определённой степени исключает влияние неоднородности характеристик регистрирующей системы по полю зрения.

Важным аспектом применения рассмотренных выше алгоритмов является зависимость результирующей точности получаемых картосхем от количества признаков. В [20] показано, что эффективность спектральной классификации ГС-данных при ОБ, сформированных случайным образом из 25 % пикселей всего изображения, имеет слабую зависимость от количества используемых признаков, если их более 10–20. Это объясняется известным в теории классификации эффектом, получившим название Hughes phenomenon [26]. Он заключается в том, что при использовании пространства признаков высокой размерности в случае фиксированного объёма обучающей выборки точность классификации при увеличении размерности пространства, начиная с некоторого её значения, не растёт, а зачастую уменьшается. Однако при выполнении спектрально-пространственной классификации с предварительным сглаживанием (алгоритм I) зависимость от числа признаков




Рис. 5. Зависимости точности методов SVM и ML спектральной (кривые 1, 3) и спектрально-пространственной (кривые 2, 4) классификаций от количества MNF-признаков

становится монотонно возрастающей. Причём при использовании большого количества признаков точность метода ML существенно выше, чем SVM, и приближается к 97 %. Это наглядно продемонстрировано на рис. 5, где приведены зависимости точности классификации исходного и предварительно сглаженного (окном 7×7 пикселей) ГС-изображений от количества признаков. Указанный эффект, по-видимому, объясняется снижением высокочастотной шумовой составляющей в изображении после его предварительной обработки.

При формировании ОБ лишь из части изображения эффективность классификации оказывается значительно ниже, а методы, основанные на учёте пространственных признаков, не позволяют добиться её существенного повышения вне зависимости от количества используемых спектральных признаков (см. рис. 4). Это объясняется тем, что пиксели одного и того же класса разных пространственных зон снимка в действительности имеют несколько отличающиеся параметры, и получаемые ОБ плохо характеризуют соответствующие классы на всём изображении.

Заключение. Проведён сравнительный анализ эффективности спектральной и спектрально-пространственной классификаций типов растительности по гиперспектральным данным при формировании обучающих выборок случайным образом из всего изображения и из его части. Установлено, что результирующая точность при указанных способах обучения в значительной степени различается. Так, при построении ОБ 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 использовании же большего количества признаков расхождение в результатах оказалось ещё более существенным. В случае 100 признаков для ОБ, сформированной из всего изображения, точность классификации составила 76,60 %, а после предварительной пространственной обработки достигла 93,13 %, тогда как для ОБ, сформированных из части изображения, точность не превысила 71,54 % и при дополнительной пространственной обработке возросла не более чем на 6 %.

Основными причинами невысокой точности классификации при обучении по части изображения (помимо схожести спектров отражения различных классов), по-видимому, 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 растительности необходимо использовать обучающие выборки с максимальной степенью распределения пикселей по всему изображению. Однако такой подход на практике трудно реализуем, поскольку в большинстве реальных задач невозможно обеспечить подспутниковые данные по всей наблюдаемой территории. Как правило, достоверные наземные данные имеются лишь на отдельных её участках и, следовательно, только по ним могут формироваться ОБ. 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.

Дальнейшие исследования в данной области целесообразно направить на разработку алгоритмов классификации, обеспечивающих повышение эффективности разделения трудноразличимых типов растительности, при обучении по отдельным фрагментам анализируемого ГС-изображения. Для этого могут быть рассмотрены алгоритмы с адаптивным формированием обучающей выборки из определённого количества пространственно наиболее близких пикселей каждого класса.

СПИСОК ЛИТЕРАТУРЫ

1. **Бондур В. Г.** Современные подходы к обработке больших потоков гиперспектральной и многоспектральной аэрокосмической информации // Исследование Земли из космоса. 2014. № 1. С. 4–16.
2. **Chan T. H., Ambikapathi A., Ma W. K., Chi C. Y.** Robust affine set fitting and fast simplex volume max-min for hyperspectral endmember extraction // IEEE Trans. Geosci. Remote Sensing. 2013. **51**, N 7. P. 3982–3997.
3. **Cawse-Nicholson K., Damelin S. B., Robin A., Sears M.** Determining the intrinsic dimension of a hyperspectral image using random matrix theory // IEEE Trans. Image Process. 2013. **22**, N 4. P. 1301–1310.
4. **Борзов С. М., Потатуркин О. И.** Классификация типов растительного покрова по гиперспектральным данным дистанционного зондирования земли // Вестн. НГУ. Сер. Информационные технологии. 2014. **12**, вып. 4. С. 13–22.
5. **Потатуркин О. И., Борзов С. М., Потатуркин А. О., Узилов С. Б.** Методы и технологии обработки мульти- и гиперспектральных данных дистанционного зондирования Земли высокого разрешения // Вычислительные технологии. 2013. **18**, спец. вып. 1. С. 60–67.
6. **Plaza A., Benediktsson J. A., Boardman J. W. et al.** Recent advances in techniques for hyperspectral image processing // Remote Sensing of Environment. 2009. **113**. P. S110–S122.
7. **Huang X., Zhang L.** An SVM ensemble approach combining spectral, structural, and semantic features for the classification of high-resolution remotely sensed imagery // IEEE Trans. Geosci. Remote Sensing. 2013. **51**, N 7. P. 257–272.
8. **Wang Z. Y., Nasrabadi N. M., Huang T. S.** Spatial-spectral classification of hyperspectral images using discriminative dictionary designed by learning vector quantization // IEEE Trans. Geosci. Remote Sensing. 2014. **52**, N 8. P. 4808–4822.
9. **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.
10. **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 Sens. 2014. **7**, N 4. P. 1047–1059.
11. **Palsson F., Ulfarsson M. O., Sveinsson J. R.** Hyperspectral image denoising using a sparse low rank model and dual-tree complex wavelet transform // Proc. of the IEEE Intern. Geoscience Remote Sensing Symp. (IGARSS). Quebec, Canada, July 13–8, 2014. P. 3670–3673.
12. **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, July 9–13, 2014. P. 138–142.
13. **Lillesand M. T., Kiefer R. W., Chipman J. W.** Remote Sensing and Image Interpretation. N. Y.: John Wiley & Sons, 2004. 763 p.
14. **Hader D. P.** Image Analysis: Methods and Applications. London: CRC Press, 2000. 480 p.
15. **Кузнецов А. В., Мясников В. В.** Сравнение алгоритмов управляемой поэлементной классификации гиперспектральных изображений // Компьютерная оптика. 2014. **38**, № 3. С. 494–502.
16. **Фурсов В. А., Бибииков С. А., Байда О. А.** Тематическая классификация гиперспектральных изображений по показателю сопряжённости // Компьютерная оптика. 2014. **38**, № 1. С. 154–158.

17. **Fauvel M., Tarabalka Y., Benediktsson J. et al.** Advances in spectral-spatial classification of hyperspectral images // Proc. of the IEEE. Institute of Electrical and Electronics Engineers. 2013. **101**, N 3. P. 652–675.
18. **Перспективные** информационные технологии дистанционного зондирования Земли /Под ред. В. А. Сойфера. Самара: Новая техника, 2015. 256 с.
19. **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.
20. **Борзов С. М., Потатуркин О. И.** Исследование эффективности спектрально-пространственной классификации данных гиперспектральных наблюдений // Автометрия. 2017. **53**, № 1. С. 32–42.
21. **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.
22. **Cristianini N., Shawe-Taylor J.** An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods. Cambridge University Press, 2000. 189 p.
23. **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.
24. **Richards J. A.** Remote Sensing Digital Image Analysis. Berlin: Springer-Verlag, 1999. 240 p.
25. **Green A. A., Berman M., Switzer P., Craig M. D.** A transformation for ordering multispectral data in terms of image quality with implications for noise removal // IEEE Trans. Geosci. Remote Sensing. 1988. **26**, N 1. P. 65–74.
26. **Hughes G. F.** On the mean accuracy of statistical pattern recognizers // IEEE Trans. Inform. Theory. 1968. **14**, N 1. P. 55–63. DOI: 10.1109/TIT.1968.1054102.

Поступила в редакцию 29 мая 2017 г.
