

УДК УДК 004.93

НЕЙРОСЕТЕВАЯ КЛАССИФИКАЦИЯ ТРУДНОРАЗЛИЧИМЫХ ТИПОВ РАСТИТЕЛЬНОСТИ ПО ГИПЕРСПЕКТРАЛЬНЫМ ПРИЗНАКАМ

© Е. С. Нежевенко

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

Экспериментально показано, что классификация фрагментов гиперспектрального изображения с предварительной трансформацией его спектральных признаков в главные компоненты и с применением пространственного преобразования Гильберта — Хуанга эффективна в случае трудноразличимых по гиперспектрам типов растительности. Проведено сравнение такой классификации с традиционными методами, когда используются гиперспектральные признаки, преобразованные в главные компоненты без привлечения пространственной информации. На конечной стадии классификации во всех методах применяются нейронные сети RBF.

Ключевые слова: классификация, гиперспектральное изображение, преобразование Гильберта — Хуанга, главные компоненты, нейронные сети.

DOI: 10.15372/AUT20190308

Введение. За последние годы произошло существенное продвижение в решении такой важной проблемы, как классификация изображений местности по их гиперспектральным измерениям [1, 2]. Исследования, подтверждаемые экспериментами на гиперспектральных изображениях (ГСИ), освещены в [3–7]. Эта проблема рассматривалась всесторонне, главное — было показано, что существенное повышение процента правильной классификации гиперспектральных изображений обеспечивает учёт пространственной структуры. Цикл работ [5–7] завершился обзором [8]. Интересна выдержка из [7]: «Дальнейшие исследования в этой области целесообразно направить на разработку алгоритмов классификации, обеспечивающих повышение эффективности разделения трудноразличимых типов растительности».

Цель представленной работы — показать, что метод, испытанный на примере небольшого фрагмента ГСИ [9], успешно решает эту проблему, которая в [8] была только обозначена. В то же время данный метод на ГСИ размерами 145×145 пикселей, размеченном на 15 классов (это изображение использовалось в [5–7]), дал 99,1 % правильной классификации на тестовой выборке и 99,7 % — на обучающей, что более чем убедительно по сравнению с большинством других методов.

Характеристика классифицируемого объекта. Для сравнения разных методов классификации важно, чтобы объекты, с которыми проводятся эксперименты, были близкими, а ещё лучше — одинаковыми. Во многих экспериментах по обработке изображений использовался объект Лена [10], при обработке ГСИ эталонными стали фрагменты изображения, полученного в рамках программы AVIRIS (Airborne Visible Infrared Imaging Spectrometer) на опытном полигоне Индиан Пайс (штат Индиана, США). Размеры изображения составили 614×2677 пикселей, разрешение 20 м/пиксел, число каналов 220 в диапазоне 0,4–2,5 мкм. Путём наземных наблюдений изображение размечено на 58 классов, из которых 15 классов кукурузы и 18 классов сои, отличающихся способами производства.

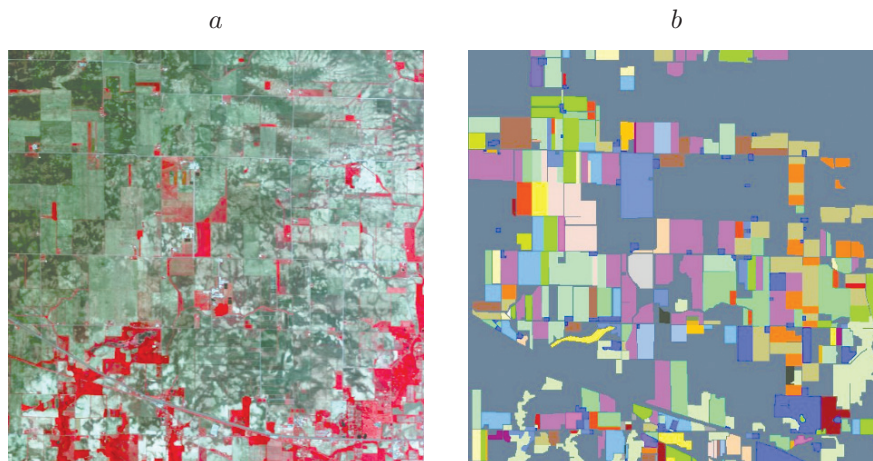


Рис. 1

Обратимся к выдержке из введения. В [6, 7] при классификации ГСИ все классы кукурузы и сои были объединены в два класса. Причина такого объединения не уточняется, но можно предполагать, если бы такое объединение не было произведено, то процент правильной классификации резко бы упал. Рассмотрим причину этой проблемы. Очевидно, что спектральные характеристики всех участков кукурузы или сои будут близки. Следовательно, повысить степень различия таких объектов можно только по пространственным признакам. В [8] проанализировано большое количество алгоритмов пространственной обработки, подавляющая часть которых сводится к тому, что значение пикселу присваивается путём обработки в его окрестности. При этом совершенно не учитываются свойства обрабатываемых структур, в результате теряются тонкие различия между ними. В [9] главные компоненты (ГК) ГСИ разлагаются на внутренние колебания (эмпирические моды), в итоге выделяются признаки, определяемые внутренней структурой того или иного фрагмента, за счёт чего и производится тонкое различие структур.

Этапы обработки. Для экспериментального подтверждения возможности тонкой классификации из вышеописанного ГСИ был выделен фрагмент (рис. 1, *a*) размерами 580×580 пикселей от 1378-го до 1957-го по вертикали и от 0-го до 579-го по горизонтали (используемый алгоритм обрабатывает квадратные фрагменты, выбран достаточно информативный участок). В него попали участки, размеченные на 44 класса (напомним, что весь полигон размечался на 58 классов). Разметка фрагмента (разбиение на классы в псевдоцветах) представлена на рис. 1, *b*.

Каждый пиксел фрагмента характеризуется 200 спектральными составляющими (в действительности их 220, но 20 самых зашумлённых исключено из обработки), которые сильно взаимно коррелированы. Поэтому они преобразованы в главные компоненты, причём для обработки отобрано пять ГК, на которые приходится 99,42 % дисперсии данных. Каждый из ГК разлагается на пять эмпирических мод (ЭМ) — это так называемое преобразование Хуанга. Поскольку подробный алгоритм уже описан в [9], здесь приведём лишь краткую информацию о нём.

Алгоритм разложения одномерной функции сигнала на ЭМ выглядит следующим образом. Определяются локальные экстремумы сигнала (минимумы и максимумы). Путём аппроксимации отдельно локальных максимумов и локальных минимумов получают огибающие сигнала. Будем иметь функцию $h_1 = x(t) - m_1$, где m_1 — среднее значение верхней и нижней огибающих и $x(t)$ — сигнал. Далее в качестве исходного сигнала берём функцию h_1 и повторяем алгоритм до выполнения порогового условия. Для его проверки вычисляем




Рис. 2

нормализованную квадратичную разность между двумя последовательными операциями отсеивания. Если $SD_k < \delta$, процесс отсеивания останавливаем.

После остановки h_k принимаем за первую ЭМ функцию c_1 . В качестве исходного сигнала r_1 берётся разность $x(t) - c_1$, и процесс повторяется. В конечном итоге имеем разложение сигнала на эмпирические моды в следующем виде:

$$x(t) = \sum_{j=1}^n c_j + r_n.$$

Алгоритм разложения двумерного сигнала на эмпирические моды формально не отличается от разложения одномерного сигнала. Однако в этом случае необходимо решить ряд проблем, главные из которых — поиск локальных экстремумов и построение огибающих сигнала по локальным экстремумам. В двумерном случае области локальных экстремумов не всегда могут быть однозначно определены. Для того чтобы избежать данной проблемы, при нахождении локальных минимумов и максимумов изображения используем морфологическую реконструкцию [11], основанную на геодезических операторах. Геодезическую реконструкцию можно задать как итерационное повторение геодезической дилатации до тех пор, пока изображение не перестанет изменяться. Таким образом, с помощью геодезической дилатации определяются максимумы изображения, а с помощью геодезической эрозии находят минимумы изображения. Метод определения минимумов и максимумов описан в [12].

Для построения огибающих в одномерном случае обычно используются кубические сплайны. Однако для двумерных изображений интерполяция кубическими сплайнами даёт сильные возмущения на краях изображений. В [13] предлагается применение радиально-базисных функций (RBF — Radial Basic Function) для интерполяции, которые могут быть представлены в виде

$$s(x) = p_m(x) + \sum_{i=1}^N \lambda_i \Phi(\|x - x_i\|),$$

где s — радиально-базисная функция, p_m — полином низкой степени, λ — коэффициент, Φ — базисная функция, x_i — центры базисных функций. Метод аппроксимации RBF имеет некоторые преимущества по сравнению с аппроксимацией сплайнами. Центры базисных функций могут не располагаться в узлах сетки. Кроме того, RBF хорошо подходит для интерполяции неоднородных данных. Для описанного двумерного преобразования была разработана программа в среде MATLAB. Каждый из четырёх ГК разлагался на пять ЭМ. Результат разложения первого ГК представлен на рис. 2.

Видно, как по мере повышения номера моды понижается частота её структуры. Таким образом, каждому из пикселей размерами 580×580 соответствует 20-мерный вектор.

Классификация участков осуществлялась с помощью предварительно обученных нейронных сетей. Для этого было исследовано несколько типов сетей: линейная сеть, многослойный персептрон, сети RBF. Наилучшие результаты классификации получены на сетях RBF. Любая классификация — это процесс нахождения набора гиперповерхностей, которые обеспечивают ограничение или оконтуривание каждого из множеств, представляющих собой отдельные классы. Такого разбиения можно достичь, описав каждое из множеств с помощью полного покрытия пространства некоторым набором гиперсфер. Нейронные сети, реализующие такую классификацию, называются сетями RBF и являются частным случаем двухслойных сетей прямого распространения. Каждый элемент скрытого слоя использует в качестве активационной функции радиальную базисную функцию типа гауссовой. Она центрируется в точке, которая определяется весовым вектором, связанным с нейроном. Позиция и ширина функции ядра должны быть обучены по выборочным образцам. Обычно ядер гораздо меньше, чем обучающих примеров. Существуют различные алгоритмы обучения сетей RBF, основной из которых использует двухшаговую стратегию обучения или смешанное обучение. Он оценивает позицию и ширину ядра с помощью алгоритма кластеризации «без учителя», а затем с использованием алгоритма минимизации среднеквадратической ошибки «с учителем» для определения весов связей между скрытым и выходным слоями. После получения этого начального приближения применяется градиентный спуск для уточнения параметров сети. Число входных нейронов сети RBF равно числу признаков распознавания, число выходных нейронов — количеству классов, число элементов в скрытом слое определяется в процессе обучения.

Результаты эксперимента (для всех классов). Основной анализ проведён для трудноразличимых классов, однако для сравнения метода, предложенного в данной работе, с известными (в частности, изложенными в [8]), представим результаты обучения-классификации для всех 44 классов, попавших в выделенный участок. Каждый размеченный участок разбивался на 3 выборки: обучающую, контрольную и тестовую в соотношении 50 : 25 : 25 %, из 10 обученных сетей RBF выбиралась наилучшая с точки зрения правильной классификации. Результаты анализа, проведённого на главных компонентах без преобразования к эмпирическим модам, показаны в первой строке табл. 1.

В первом столбце таблицы приведена архитектура нейронной сети: тип сети, количество входных нейронов, число функций RBF в скрытом слое и число выходных нейронов. Очевидно, что точность классификации 49,5 % не может считаться удовлетворительной. Перейдём к результатам обучения-классификации на данных, преобразованных сначала в ГК, а затем каждый отобранный ГК разложен на внутренние моды, из которых выделяются признаки распознавания (это уже преобразование Гильберта — Хуанга). Результаты такой обработки представлены во второй строке табл. 1.

Общая точность классификации тестовой выборки составила 67,9 %, т. е. за счёт пространственной обработки она повысилась на 18,4 %, что можно считать неплохим результатом, учитывая, что все участки кукурузы и сои классифицировались отдельно. Однако главный эксперимент — классификация различных вариантов участков кукурузы и сои.

Таблица 1

Результаты классификации по 44 классам

Архитектура сети / система признаков	Точность классификации		
	обучающая выборка	контрольная выборка	тестовая выборка
RBF 5-700-44 / ГК	0,525	0,503	0,495
RBF 20-1500-44 / ЭМГК	0,792	0,712	0,679

Таблица 2

Результаты классификации кукурузы и сои по 26 классам

Архитектура сети / система признаков	Точность классификации		
	обучающая выборка	контрольная выборка	тестовая выборка
RBF 5-700-26 / ГК	0,558	0,528	0,542
RBF 20-1500-26 / ЭМГК	0,907	0,883	0,888

Таблица 3

Классы кукурузы и сои

Номер класса	Тип растительности и характеристика участка
5	Кукуруза
6	Кукуруза?
7	Кукуруза — запад-восток
8	Кукуруза — север-юг
9	Кукуруза — обычная вспашка
12	Кукуруза — обычная вспашка — орошаемая — север-юг
14	Кукуруза — малоразрушающая вспашка
15	Кукуруза — малоразрушающая вспашка — запад-восток
16	Кукуруза — малоразрушающая вспашка — север-юг
17	Кукуруза — без вспашки
18	Кукуруза — без вспашки — запад-восток
36	Соевые бобы
38	Соевые бобы?
39	Соевые бобы — север-юг
41	Соевые бобы — обычная вспашка — запад-восток
42	Соевые бобы — обычная вспашка — север-юг
43	Соевые бобы — обычная вспашка — посадка в борозду
44	Соевые бобы — заросшие сорняками — обычная вспашка
45	Соевые бобы — посадка в борозду
46	Соевые бобы — малоразрушающая вспашка
47	Соевые бобы — малоразрушающая вспашка — запад-восток
48	Соевые бобы — малоразрушающая вспашка — посадка в борозду
49	Соевые бобы — малоразрушающая вспашка — север-юг
51	Соевые бобы — без вспашки — запад-восток
52	Соевые бобы — без вспашки — север-юг
53	Соевые бобы — без вспашки — посадка в борозду

Результаты эксперимента (для классов кукурузы и сои). В выделенный фрагмент размерами 580 × 580 пикселей попало 11 участков кукурузы и 15 участков сои — всего 26 участков из 36. Сначала покажем результаты моделей для классификации участков кукурузы и сои по главным компонентам без пространственной обработки (табл. 2, первая строка).

Точность классификации 54 % чуть выше, чем для 44 классов. Для эксперимента с пространственной обработкой был сформирован файл, состоящий из пикселей, принадлежащих согласно разметке 11 классам кукурузы и 15 классам сои. Размеры файла 20 × 105470, где 20 — это пять ГК и четыре ЭМ, а 105470 — общее число всех пикселей, попавших в размеченные участки. Число пикселей в каждом классе разное, разбиение на обучающую, тестовую и контрольную выборки прежнее (50 : 25 : 25 %). Пиксели для всех выборок отбирались случайно. Обучающая выборка загружалась в нейронную сеть, тип сети RBF, максимальное число элементов в скрытом слое 1500. Обучение проходило по методу об-

Таблица 4

Классификация кукурузы и сои

Класс	Всего	Правильно	Ошибочно	% правильных	% ошибочных
5	1582	1350	232	85,34	14,67
6	250	189	61	75,60	24,40
7	1500	1369	131	91,27	8,73
8	6596	6024	572	91,33	8,67
9	12144	11286	858	92,93	7,07
12	1728	1430	298	82,76	17,25
14	4816	4299	517	89,27	10,74
15	5943	5438	505	91,50	8,50
16	1974	1642	332	83,18	16,82
17	960	797	163	83,02	16,98
18	5685	5259	426	92,51	7,49
36	894	767	127	85,79	14,21
38	2124	1538	586	72,41	27,59
39	2726	2270	456	83,27	16,73
41	6042	5188	854	85,87	14,13
42	820	682	138	83,17	16,83
43	543	543	0	100,0	0,00
44	6127	5696	431	92,97	7,03
45	1011	803	208	79,43	20,57
46	1832	1630	202	88,97	11,03
47	2951	2615	336	88,61	11,39
48	2674	2298	376	85,94	14,06
49	1940	1759	181	90,67	9,33
51	929	805	124	86,65	13,35
52	8260	7795	465	94,37	5,63
53	583	575	8	98,63	1,37

ратного распространения ошибки, оптимизация проводилась методом сопряжённых градиентов, время обучения составило несколько часов. Завершение обучения определялось по «поведению» правильной классификации контрольной выборки. Проанализируем результаты подробнее, оставив, как и ранее, самую эффективную сеть из 10 исследованных (табл. 2, вторая строка).

Общую точность классификации тестовой выборки 88,8 % можно считать достаточно хорошей. Однако интересны тонкости различения участков одних и тех же культур по классам с учётом незначительных различий между ними. В табл. 3 сведены все попавшие в выделенный фрагмент участки с описанием характеристик.

Их нумерация позволит идентифицировать эти участки в экспериментальных данных. В табл. 4 представлены результаты классификации с разделением на классы.

Видно, что они очень неравномерны: класс 43 (обычная вспашка, посадка в борозду) со 100 %-ной правильной классификацией, а класс 6 (кукуруза под вопросом) — всего 75,6 %. В большинстве классов правильно классифицировано около 90 % участков. Интерес представляет также матрица ошибок (табл. 5), позволяющая видеть классы с неправильно классифицированными данными. Каждая строчка матрицы нормирована на число правильно классифицированных в соответствующих классах пикселей. Участки с 5 по 18 — кукуруза, а с 36 по 53 — соя.

Чтобы узнать распределение ошибок в конкретном классе, находим номер класса в верхней строке таблицы, в столбце с этим номером указано, сколько процентов пикселей класса распознаны как пиксели других классов, номера которых указаны в первом

Таблица 5

Нормированная матрица ошибок при классификации кукурузы и сои по 26 классам, выраженная в %

N	5	6	7	8	9	12	14	15	16	17	18	36	38	39	41	42	43	44	45	46	47	48	49	51	52	53	
5	100	0,00	0,00	0,30	1,41	0,00	0,15	0,07	0,07	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,07	0,00	2,81	0,00	1,04	0,00	0,00	0,00	0,00	
6	0,00	100	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	3,17	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
7	0,58	0,22	100	0,29	0,29	0,00	0,29	0,00	0,07	0,00	0,00	0,00	0,22	0,00	0,07	0,00	0,00	0,00	0,00	0,00	0,22	0,00	0,00	0,00	0,00	0,00	0,00
8	0,07	0,00	0,05	100	1,78	1,13	0,85	0,08	0,08	0,15	0,78	0,12	0,71	0,40	1,61	1,34	0,00	1,44	0,43	0,05	0,58	0,27	0,28	0,03	1,15	0,00	
9	0,66	0,39	0,45	1,42	100	0,67	1,84	0,69	0,77	0,44	0,90	0,33	1,05	1,22	2,53	0,24	0,00	0,85	0,15	0,58	0,74	0,23	0,62	0,02	0,77	0,04	
12	0,00	0,00	0,21	0,70	0,98	100	0,91	0,14	0,00	0,00	0,00	0,00	0,07	0,49	0,42	0,00	0,00	0,00	0,00	0,00	0,00	0,14	0,00	0,00	0,00	0,00	
14	0,65	0,28	0,00	0,42	1,54	0,07	100	0,70	0,51	0,16	0,12	0,00	0,54	0,44	0,98	0,00	0,00	0,67	0,07	1,02	0,16	0,98	0,19	0,02	0,33	0,00	
15	0,07	0,00	0,07	0,57	0,72	0,24	0,64	100	0,35	0,07	0,24	0,04	1,18	0,42	1,27	0,02	0,00	0,70	0,07	0,00	0,51	0,86	0,29	0,37	0,88	0,00	
16	0,00	0,00	0,06	0,24	0,12	0,00	0,00	0,00	100	0,00	0,85	0,00	0,24	0,00	0,00	0,00	0,00	0,18	0,37	0,00	0,43	0,12	0,00	0,00	0,73	0,00	
17	0,00	0,00	0,00	2,38	0,88	0,00	0,13	0,50	0,25	100	0,00	0,00	0,00	0,38	0,00	0,00	0,00	1,51	0,00	0,00	0,75	0,00	0,00	0,00	0,38	0,00	
18	0,08	0,00	0,23	0,97	0,74	0,40	0,21	0,63	0,82	0,00	100	0,00	1,08	0,21	0,44	0,34	0,00	0,48	0,36	0,00	0,36	0,61	0,06	0,49	1,24	0,00	
36	0,26	0,00	0,00	0,00	0,65	0,00	0,26	0,00	0,00	0,00	0,00	100	0,00	0,00	0,13	0,00	0,00	0,00	0,00	0,00	0,00	0,78	0,00	0,00	0,00	0,00	
38	0,06	0,00	0,84	1,75	1,10	0,06	0,52	0,32	0,13	0,06	0,00	0,00	100	0,91	0,71	0,00	0,00	0,26	0,00	0,00	0,06	0,00	0,13	0,00	1,49	0,00	
39	0,04	0,00	0,13	0,79	1,28	0,97	0,09	0,48	0,04	0,18	0,48	0,00	0,48	100	0,57	0,00	0,00	1,19	0,00	0,00	0,70	0,13	0,09	0,00	0,09	0,00	
41	0,06	0,00	0,31	0,94	2,72	0,29	1,10	1,21	0,17	0,40	0,42	0,06	1,08	1,81	100	0,02	0,00	0,42	0,21	0,10	0,25	1,20	0,08	0,06	0,35	0,02	
42	0,00	0,00	0,00	1,17	0,00	0,00	0,29	0,00	0,15	0,00	0,00	0,00	1,17	1,17	0,73	100	0,00	0,29	0,00	0,00	0,15	0,15	0,00	0,00	0,00	0,00	
43	0,00	0,00	0,00	0,00	0,18	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	100	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,92	0,00	
44	0,09	0,00	0,16	1,33	2,35	0,30	0,46	0,42	0,53	0,40	0,68	0,23	0,88	0,95	2,02	0,02	0,00	100	0,23	0,19	0,84	0,51	0,46	0,00	1,39	0,04	
45	0,00	0,00	0,00	0,00	0,37	0,00	0,00	0,00	4,86	0,00	0,00	0,00	0,00	0,00	0,12	0,00	0,00	0,12	100	0,00	0,00	0,12	0,00	0,00	0,12	0,00	
46	1,90	0,00	0,00	0,18	0,67	0,00	0,80	0,06	0,06	0,00	0,00	0,00	0,12	0,06	0,55	0,00	0,00	0,00	0,00	100	0,06	0,18	0,00	0,06	0,00	0,00	
47	0,80	0,08	0,08	0,19	0,73	0,23	0,15	1,53	0,23	0,04	0,27	0,00	0,61	1,11	0,27	0,00	0,00	0,80	0,80	0,15	100	1,07	0,00	0,38	1,11	0,00	
48	0,26	0,00	0,57	1,04	1,13	2,05	0,35	0,70	0,13	0,00	0,39	2,09	0,26	0,13	0,70	0,00	0,00	0,04	0,00	0,00	0,13	100	0,00	0,87	0,39	0,00	
49	0,11	0,00	0,00	0,00	0,85	0,11	0,00	0,85	0,63	0,63	1,88	0,00	0,00	0,00	0,57	0,00	0,00	0,28	2,33	0,06	0,11	0,17	100	0,00	0,00	0,00	
51	0,00	0,00	0,00	0,00	0,00	0,00	1,12	2,98	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,99	0,00	0,00	100	0,12	0,00	
52	0,47	0,00	0,01	0,76	1,72	0,09	0,77	1,35	0,63	0,41	1,55	0,22	1,58	0,36	1,68	0,12	0,00	0,72	0,60	0,38	0,69	0,74	0,42	0,50	100	0,01	
53	0,00	0,00	0,00	0,35	0,52	0,00	0,17	0,00	0,00	0,00	0,52	0,00	0,00	0,00	0,87	0,00	0,00	0,17	0,00	0,00	0,00	0,17	0,00	0,00	0,00	100	

столбце. Интерес представляют максимальные проценты ошибок. На первый взгляд, максимальные перекрёстные ошибки должны дать классы, характеризующиеся различными видами вспашки с севера на юг и с запада на восток. Однако это не так, что следует из перечисления всех участков, имеющих ошибки отнесения к другому классу более 3 %. Максимальная ошибка 4,86 % отнесения пикселей класса 16 «кукуруза — малоразрушающая вспашка — север–юг» к классу 45 «соевые бобы — посадка в борозду». Ошибка 3,65 % отнесения пикселей класса 9 «кукуруза — обычная вспашка» к классу 36 «соевые бобы». И ошибка 3,1 % отнесения пикселей класса 41 «соевые бобы — обычная вспашка — запад–восток» к классу 6 «кукуруза?». Единственная логичная (с точки зрения направления вспашки) достаточно большая ошибка 2,98 % отнесения пикселей класса 15 «кукуруза — малоразрушающая вспашка — запад–восток» к классу 51 «соевые бобы — без вспашки — запад–восток».

Заключение. Таким образом, в данной работе экспериментально показано, что при классификации гиперспектральных изображений преобразование в главные компоненты спектральных составляющих и дальнейшее пространственное преобразование путём разложения главных компонентов на эмпирические моды обеспечивает формирование эффективной системы признаков распознавания. Эта система позволяет после обучения нейронной сети проводить с её помощью тонкую классификацию гиперспектральных изображений и обеспечивает высокую вероятность правильной классификации достаточно близких по спектральному составу и трудноразличимых обычными методами участков местности.

Благодарности. Автор выражает благодарность канд. техн. наук С. М. Борзову за полезные замечания.

Финансирование. Работа выполнена при поддержке Министерства высшего образования и науки РФ (государственная регистрация № АААА-А17-117052410034-6).

СПИСОК ЛИТЕРАТУРЫ

1. **Перспективные** информационные технологии дистанционного зондирования Земли /Под ред. В. А. Соифера. 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. **Кузнецов А. В., Мясников В. В.** Сравнение алгоритмов управляемой поэлементной классификации гиперспектральных изображений // Компьютерная оптика. 2014. **38**, № 4. С. 494–502.
4. **Фурсов В. А., Бибииков С. А., Байда О. А.** Тематическая классификация гиперспектральных изображений по показателю сопряжённости // Компьютерная оптика. 2014. **38**, № 1. С. 154–158.
5. **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.
6. **Борзов С. М., Потатуркин О. И.** Исследование эффективности спектрально-пространственной классификации данных гиперспектральных наблюдений // Автометрия. 2017. **53**, № 1. С. 32–42.
7. **Борзов С. М., Потатуркин О. И.** Классификация гиперспектральных изображений при различных способах формирования обучающих выборок // Автометрия. 2018. **54**, № 1. С. 89–97.
8. **Борзов С. М., Потатуркин О. И.** Спектрально-пространственные методы классификации гиперспектральных изображений. Обзор // Автометрия. 2018. **54**, № 6. С. 64–86.

9. **Нежевенко Е. С., Феокистов А. С., Дашевский О. Ю.** Нейросетевая классификация гиперспектральных изображений на основе преобразования Гильберта — Хуанга // Автометрия. 2017. **53**, № 2. С. 79–85.
10. **Лена.** Материал из Википедии. URL: [https://ru.wikipedia.org/wiki/Лена_\(изображение\)](https://ru.wikipedia.org/wiki/Лена_(изображение)) (дата обращения: 29.04.2019).
11. **Beucher S.** Geodesic reconstruction, saddle zones and hierarchical segmentation // Image Anal. Stereol. 2001. **20**, N 2. P. 137–141.
12. **Vincent L.** Morphological grayscale reconstruction in image analysis: Applications and efficient algorithms // IEEE Trans. Image Process. 1993. **2**, N 2. P. 176–201.
13. **Carr J. C., Fright W. R., Beatson R. K.** Surface interpolation with radial basis functions for medical imaging // Proc. of the Conf. ACM SIGGRAPH. Los Angeles, USA, 12–17 Aug., 2001. P. 67–76.

Поступила в редакцию 29.04.2019

После доработки 07.05.2019

Принята к публикации 07.05.2019
