

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 004.93

СОКРАЩЕНИЕ РАЗМЕРНОСТИ СИСТЕМЫ ПРИЗНАКОВ ПРИ КЛАССИФИКАЦИИ ГИПЕРСПЕКТРАЛЬНЫХ ДАННЫХ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ

© В. И. Козик, Е. С. Нежевенко

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

Гиперспектральный метод анализа земной поверхности весьма эффективен при решении проблем классификации как объектов, находящихся на ней, так и состояния этих объектов (например, сельскохозяйственных культур). Однако полномасштабный гиперспектральный анализ — очень дорогая процедура, и вполне объяснимы поиски путей её удешевления. Самый логичный способ — это сокращение числа спектральных составляющих (признаков классификации) путём выбора (или формирования из них) наиболее информативных. Предлагается осуществлять его путём применения нейросетевых технологий. На примере обработки 200-канального гиперспектрального изображения показано, что сокращение размерности пространства признаков с использованием указанных технологий позволяет достичь при классификации высоких значений точности, превосходящих получаемые при применении известных методов.

Ключевые слова: дистанционное зондирование Земли, гиперспектральные изображения, классификация, нейронные сети, обучение, генетический алгоритм, сокращение количества признаков.

DOI: 10.15372/AUT20220101

Введение. Анализ земной поверхности с помощью гиперспектральной съёмки является эффективным методом исследования, применимым в самых различных приложениях. Отметим, что эта задача относится к классу задач по распознаванию и важнейшим этапом при их решении является выбор системы признаков. В большинстве публикаций в качестве такой системы выступают главные компоненты [1–3]. Понятно, что это упрощает само распознавание, поскольку входной вектор признаков сокращается по сравнению с исходными гиперспектральными признаками, однако для получения последних (а их количество достигает сотен) требуется сложная и дорогая аппаратура. Решение этой проблемы подробно изложено в работе [4]. На смену дисперсионным элементам для разбиения входного излучения на набор полос с разными длинами волн приходят узкие спектральные фильтры, нанесённые на поверхность КМОП-сенсора. В этом варианте аппаратура спектрального анализа существенно упрощается, но возникает важная проблема выбора минимального набора признаков, обеспечивающих требуемую точность классификации. Частично эти вопросы рассмотрены в [4], кроме таких эффективных способов сокращения количества признаков (что следует из современной научной литературы), как нейросетевые и генетические.

Целью предлагаемой работы является исследование возможности сокращения размерности пространства признаков при классификации гиперспектральных изображений (ГСИ) этими методами.




Рис. 1

Исходные данные. В качестве исходных данных используем ГСИ, полученное в рамках программы AVIRIS на опытном полигоне Indian Pines [5]. Объяснение этому — его уникальные свойства: снимок достаточно большого размера (2677×614 пикселей), фрагмент 1408×614 пикселей размечен на классы, 1 пиксел составляет 20 м, каждому пикселу соответствует 220 спектральных составляющих в диапазоне 0,4–2,5 мкм (из них 20 сильно зашумлены, поэтому они исключаются из рассмотрения). На снимке выделено 57 самых разнообразных классов — от естественной растительности и культурных посевов до зданий и асфальта. Из этого изображения выделим информативный участок размером 145×145 пикселей. Сам участок и его разметка на классы в псевдоцветах показаны на рис. 1.

Методы исследования. Все эксперименты проведены в программе Statistica. В ней имеется нейропакет [6], в котором конструируются нейронные сети для классификации — по умолчанию на одну выборку исходных данных 20 вариантов (типов с разными параметрами). Типы сетей: многослойные перцептроны, радиально-базисные сети, их параметры (число нейронов в скрытом слое, параметры обучения) — подбираются в процессе классификации по критерию максимального значения точности классификации. Проводятся обучение каждой нейронной сети и классификация с её использованием, после чего пользователю по умолчанию предоставляется пять сетей с наилучшими значениями точности классификации. Кроме того, в процессе обучения-классификации вычисляются другие статистические параметры, которые будут отмечены далее.

На вход нейронных сетей поступают значения признаков пикселей ГСИ. Каждый пиксел характеризуется набором значений яркости спектральных составляющих. Как уже отмечалось, количество спектральных составляющих в исходном ГСИ — 200 (табл. 1). Соответственно число нейронов входного слоя сетей, применяемых для обработки таких данных, равно числу признаков.

Первый столбец таблицы — номер пиксела фрагмента изображения, для малого фрагмента его максимальное значение 21025, для полного изображения — 864512. Второй столбец — номер класса пиксела, всего классов 57. Значения в верхней строке для исходного изображения от 1 до 200 — номера спектральных составляющих, 200 значений в каждой следующей строке — спектральные составляющие одного пиксела. В используемой программе весь набор пикселей делится случайным образом на 3 части в соотношении 0,7 : 0,15 : 0,15. Первая часть применяется для обучения нейронных сетей (обучающая выборка (ОВ)), вторая — для оценки качества сети в процессе обучения в целях подбора параметров и остановки обучения (тестовая выборка (ТВ)), третья — для проверки эффективности сети после окончания процедуры обучения (валидационная выборка (ВВ)). Иногда, если число эпох обучения заранее установлено, вторая выборка присоединяется

Таблица 1

Фрагмент оцифрованного ГСИ

Канал		1	2	3	4	5	6	7	8	9
Пиксел	Класс	Спектральные составляющие								
1	3	3687	4266	4421	4498	5019	5293	5438	5427	5383
2	3	2749	4258	4603	4493	4958	5234	5417	5355	5349
3	3	2746	4018	4675	4417	4886	5117	5215	5096	5098
4	3	2575	4262	4320	4337	4696	4911	4957	4900	4848
5	3	2575	4134	4333	4198	4482	4833	4962	4657	4666
6	3	2575	4014	4590	4284	4663	5038	5026	4921	4905
7	3	2578	4142	4413	4488	4777	5136	5192	5113	5043
8	3	2754	4273	4417	4341	4782	5112	5144	5062	4990
9	3	3858	4517	4497	4270	4815	4872	5091	4983	4888
10	3	2746	4382	4324	4274	4530	4916	4995	4962	4913

Таблица 2

Точность классификации при 200 признаках

Номер	Сеть	Точность классификации		
		ОВ	ТВ	ВВ
1	MLP 200-47-16	91,24	88,61	87,50
2	MLP 200-49-16	93,05	89,85	89,85
3	MLP 200-41-16	95,59	90,70	89,46

к третьей. Отношение числа правильно классифицированных пикселей к общему числу пикселей обрабатываемого ГСИ называется точностью классификации. Общая схема многослойного персептрона показана на рис. 2. Здесь 3 слоя: входной слой $x_1—x_n$, где n определяется числом спектральных составляющих; скрытый полносвязный слой, число нейронов в котором изменяется программой при переборе сетей, и выходной слой, число нейронов m в нём определяется количеством классов, на которые делится изображение. Коэффициенты связи w вычисляются в процессе обучения, которое проводится методом обратного распространения ошибки. Путём перебора параметров по результатам классификации ВВ выбирается лучшая сеть, и для этой сети осуществляется анализ её чувствительности к различным признакам. Второй метод, использованный в данной работе, — генетический. В теории распознавания показано, что возможны варианты, когда выбор комбинации признаков даёт лучшую точность классификации, чем выбор наиболее эффективных признаков по отдельности. Способом найти такую комбинацию является генетический алгоритм, который действует по принципу естественного отбора, происходящего в живой природе.

Результаты экспериментов. Рассмотрим эксперименты, основанные на анализе чувствительности сети к различным признакам.

Сначала выполним классификацию с использованием всех 200 признаков. Некоторые базовые параметры сетей (тип сети, диапазон изменения числа нейронов в скрытом слое) выбирались на основе опыта авторов. Остальные параметры перебирала программа обучения.

Параметры трёх наиболее эффективных сетей из 20 испытанных многослойных персептронов и полученные с их применением точности классификации на ОВ, ТВ и ВВ приведены в табл. 2.

В столбце Сеть отображены число входных нейронов (число спектральных признаков — 200), число скрытых слоёв (41–49), число выходных нейронов (число классов — 16). Максимальная точность классификации на валидационной выборке рав-

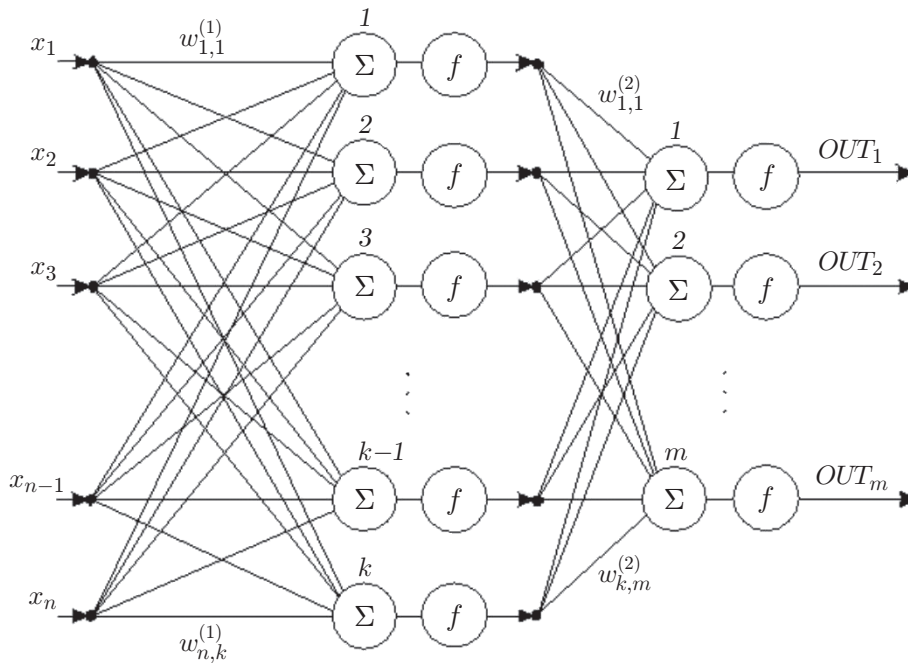


Рис. 2

Таблица 3

Точность классификации при 10 признаках, выбранных по чувствительности

Сеть	Точность классификации		
	ОВ	ТВ	ВВ
MLP 10-43-16	90,38	88,03	88,94

на 89,85 %, сеть с этим значением выбирается для дальнейшего анализа. Для объединения признаков в группы используем данные по признаку чувствительности, вычисляемые после обучения по результатам классификации. Чувствительность показывает, во сколько раз увеличится ошибка модели, если убрать соответствующие признаки из анализа. Если чувствительность меньше единицы, то удаление данного признака улучшает качество работы сети. Ранжированный ряд значений чувствительности — основа для формирования наиболее информативных спектральных интервалов за счёт объединения идущих подряд спектральных признаков, чувствительность к которым превышает заданный порог. Усреднённые значения каналов в пределах полученных интервалов становятся новыми признаками. Сгруппировав таким образом признаки, выберем 10 наиболее значимых интервалов: 8–9, 18–19, 21–27, 30–39, 42–44, 100–103, 109–123, 129–144, 148–169, 170–193. Для работы с такими данными входной слой нейронной сети должен содержать 10 нейронов. Точность классификации для такой сети с наилучшим показателем представлена в табл. 3.

Видно, что максимальная точность классификации составляет 88,94 %, т. е. всего на 0,91 % меньше, чем при полном наборе признаков. Отметим, что в работе [4] точность по 10 признакам составила 88,21 %. Для обучающей выборки точность равна 90,38 %, что обозначает отсутствие переобучения в данном случае.

Рассмотрим теперь использование генетического алгоритма для сокращения пространства признаков [7]. Он также реализуется в нейропакете программы Statistica. При этом задаются следующие параметры генетического алгоритма: популяция — 100, число поколений — 100, скорость мутации — 0,1, скорость скрещивания — 1.

Таблица 4

Значимость признаков для различных каналов

Канал	Значимость	Канал	Значимость	Канал	Значимость	Канал	Значимость
139	Да	144	Да	149	Да	154	Да
140	Да	145	—	150	Да	155	Да
141	Да	146	—	151	Да	156	Да
142	Да	147	—	152	Да	157	Да
143	Да	148	Да	153	Да	158	—

Таблица 5

Точность классификации по 61 признаку, выбранному по чувствительности

Сеть	Точность классификации		
	ОВ	ТВ	ВВ
MLP 61-33-16	90,63	85,23	86,6

В табл. 4 приведён фрагмент результата отбора наиболее значимых признаков.

Точность классификации для сети, в которую введены признаки с индексом «Да», показана для MLP 61-33-16 в табл. 5.

Генетический алгоритм счёл значимым 61 признак, а максимальная точность составила 86,6 %. Конечно, по этому результату вряд ли можно судить о его эффективности. Возможно, для такого высокоразмерного входного вектора необходимо изменять значения параметров генетического алгоритма в более широком диапазоне, однако для реализации такого алгоритма требуется слишком много времени. Поэтому проводить исследования в этом направлении мы сочли нецелесообразным.

До сих пор работа была сосредоточена на не слишком большом фрагменте (145×145). Безусловно, интерес представляет обработка крупноразмерных фрагментов, приведём результаты обработки фрагмента размером 1408×614 пикселей. Прежде всего посмотрим, что даёт обработка, когда каждый пиксел характеризуется 200 спектральными признаками. Результат классификации приведён в первой строке табл. 6.

Из таблицы видно, что в случае обучения многослойного персептрона на 57 классах при 18 нейронах в скрытом слое точность классификации валидационной выборки составляет 58,02 %. Причина такой низкой точности заключается в наличии очень большого количества «плохих» классов (напомним, что во фрагменте 145×145 было всего 16 классов). Для определения этих классов используем получаемую в результате обработки точность классификации для каждого класса (в табл. 6 показан фрагмент из общего числа 57 классов, представленных в четвёртой строке таблицы).

По этой таблице отбираются классы, в которых правильная классификация составляет больше 50 %. Их количество 34. Обученная для этих классов нейронная сеть MLP 200-31-34 показана во второй строке табл. 7, она даёт точность классификации на валидационной выборке 76,75 %.

В результате обучения при 34 классах была получена информация о чувствительности сети к различным признакам и по ней сформировано 10 спектральных интервалов по принципу максимальной чувствительности. Точность классификации многослойным персептроном MLP 10-39-34 представлена в первой строке табл. 8.

Как и следовало ожидать, точность классификации (66,6 %) в этом случае ниже, чем при использовании всех 200 признаков, но здесь можно при измерении спектральных характеристик использовать принцип «filter-on-chip», заключающийся в нанесении узких спектральных фильтров непосредственно на поверхность КМОП-сенсора [8, 9].

Таблица 6

Результат классификации для фрагмента 1408 × 614 сети MLP 200-18-57

Признаки	Всего пикселей	Верно	Неверно	Верно (%)	Неверно (%)
1	41	0	41	0,00	100,00
10	27990	20136	7854	71,94	28,06
11	561	320	241	57,04	42,96
12	1218	347	871	28,49	71,51
13	672	346	326	51,49	48,51
14	3986	166	3820	4,165	95,83
15	6339	3245	3094	51,19	48,81
16	3099	0	3099	0,00	100,00

Таблица 7

Точность классификации при 200 признаках для фрагмента 1408 × 614

Сеть	Точность классификации		
	ОВ	ТВ	ВВ
MLP 200-18-57	58,52	58,72	58,02
MLP 200-31-34	77,57	76,47	76,75

Таблица 8

Точность классификации при 10 признаках для фрагмента 1408 × 614

Сеть	Точность классификации		
	ОВ	ТВ	ВВ
MLP 10-39-34	66,30	66,31	66,6
MLP 10-47-15	79,84	79,62	79,88

Интерес также представляет вариант, в котором классы кукурузы и сои будут объединены внутри: в один класс кукурузы и в один класс сои. Это объединение можно произвести двумя способами: объединить в один класс все 6 классов кукурузы и в другой класс — все 15 классов сои. А можно сначала все классы подать на вход нейронной сети по отдельности и суммировать точность классификации уже на выходе. При объединении классов кукурузы и сои вторым способом точность классификации получилась 78,5 %. Лучшая точность 79,9 % достигнута при объединении кукурузы и сои первым способом, точность классификации представлена во второй строке табл. 8 для MLP 10-47-15.

Число классов на выходе нейронной сети считается следующим образом. Всего распознаётся 34 класса. Из них вычитается 6 классов кукурузы и 15 классов сои. Затем добавляется два объединённых класса кукурузы и сои. Результат: $34 - 6 - 15 + 2 = 15$. Таким образом, на выходе нейронной сети появляется 15 классов. Точность классификации 79,9 % при 10 признаках для большого фрагмента — достаточно высокий результат. Как следует из экспериментов, лучшим способом объединения нескольких классов является объединение на входе.

Сводная информация точностей классификации при различных размерах фрагментов, количестве признаков, количестве классов и в случае их объединения представлена в табл. 9.

Таблица 9

Сводная таблица точности классификации

Размер фрагмента	Число признаков	Число классов	Объединение классов	Способ сокращения признаков	Точность классификации, %
145 × 145	200	16	Нет	Без сокращения	89,85
	10	16	Нет	По чувствительности	88,94
		16	Нет	Генетический	86,6
1608 × 614	200	57	Нет	Без сокращения	58,02
		34	Нет	Без сокращения	76,75
	10	34	Нет	По чувствительности	66,6
		15	Да	По чувствительности	79,88

Заключение. Исследованы методы сокращения подсистем признаков при распознавании гиперспектральных изображений путём использования нейросетевых технологий. Экспериментально показано, что нейронные сети при сокращении числа признаков до 10 обеспечивают более высокую точность классификации, чем другие методы: для фрагмента 145 × 145 — 88,94 %, для фрагмента 1608 × 614 — 66,6 %.

Это вполне естественно, поскольку такая классификация относится к категории искусственного интеллекта, а именно в этой области (что можно считать уже установленным) нейронные сети являются наиболее эффективными. К сожалению, не дал хороших результатов генетический метод, но это можно объяснить техническими проблемами: для его всестороннего исследования требуются значительные вычислительные мощности и временные затраты.

Благодарности. Авторы выражают благодарность канд. техн. наук С. М. Борзову за полезные обсуждения.

Финансирование. Работа выполнена при поддержке Министерства науки и высшего образования в рамках выполнения работ по Государственному заданию № 121022000116-0 в ИАиЭ СО РАН.

СПИСОК ЛИТЕРАТУРЫ

1. **Craig R., Jie S.** Principal component analysis for hyperspectral image classification // *Surv. and Land Inform. Syst.* 2002. **62**, N 2. P. 115–122.
2. **Нежевенко Е. С.** Нейросетевая классификация трудноразличимых типов растительности по гиперспектральным признакам // *Автометрия.* 2019. **55**, № 3. С. 62–70. DOI: 10.15372/AUT20190308.
3. **Козик В. И., Нежевенко Е. С.** Классификация гиперспектральных изображений с помощью свёрточных нейронных сетей // *Автометрия.* 2021. **57**, № 2. С. 13–21. DOI: 10.15372/AUT20210202.
4. **Борзов С. М., Потатуркин О. И.** Выбор информативной системы признаков при классификации сельскохозяйственных культур по гиперспектральным данным // *Автометрия.* 2020. **56**, № 4. С. 134–144. DOI: 10.15372/AUT20200414.
5. **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.

6. **STATISTICA Neural Networks**: Методология и технологии современного анализа данных / Под ред. В. П. Боровикова. 2-е изд., перераб. и доп. М.: Горячая линия — Телеком, 2008. 392 с.
7. **Саймон Д.** Алгоритмы эволюционной оптимизации. М.: ДМК Пресс, 2020. 940 с.
8. **Tack N., Lambrechts A., Soussan S., Haspeslagh L.** A compact, high-speed, and low-cost hyperspectral imager // Proc. SPIE. 2012. **8266**. 82660Q1-13.
9. **Geelen B., Tack N., Lambrechts A.** A snapshot multispectral imager with integrated tiled filters and optical duplication // Proc. SPIE. 2013. **8613**. 861314.

Поступила в редакцию 18.11.2021

После доработки 12.12.2021

Принята к публикации 28.12.2021
