

АНАЛИЗ И СИНТЕЗ СИГНАЛОВ И ИЗОБРАЖЕНИЙ

УДК 528.72:004.93

ВЫБОР ИНФОРМАТИВНОЙ СИСТЕМЫ ПРИЗНАКОВ ПРИ КЛАССИФИКАЦИИ СЕЛЬСКОХОЗЯЙСТВЕННЫХ КУЛЬТУР ПО ГИПЕРСПЕКТРАЛЬНЫМ ДАННЫМ

© 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*

Методы, основанные на обработке данных видеосъёмки, показали свою эффективность во многих областях сельского и лесного хозяйств. Тем не менее они недостаточно точны для классификации слаборазличимых объектов и типов растительности, что можно обеспечить только за счёт применения гиперспектральных сенсоров. Но такие устройства до настоящего времени были дороги и сложны в эксплуатации и использовались в основном на спутниках и пилотируемых самолётах. В последние годы предложены технологии создания более компактных и лёгких сенсоров, основанных на выборе на этапе проектирования ограниченного числа спектральных интервалов и их расположения. Они могут использоваться для научных или коммерческих целей в полевых условиях и, кроме того, быть установлены на беспилотных летательных аппаратах. В данной работе на примере 220-канального гиперспектрального изображения экспериментально исследована возможность существенного уменьшения объёма регистрируемых данных за счёт выбора положения и ширины ограниченного количества наиболее информативных спектральных каналов при решении задачи классификации сельскохозяйственных культур. Показано, что применяемый метод формирования систем признаков имеет существенное преимущество по сравнению с регулярным прореживанием и близок по эффективности к методам на основе анализа главных компонент, обладая при этом существенно меньшей требуемой трудоёмкостью вычислений.

Ключевые слова: дистанционное зондирование Земли, гиперспектральные изображения, классификация сельскохозяйственных культур, выбор информативных признаков.

DOI: 10.15372/AUT20200414

Введение. В настоящее время активно развиваются методы и средства дистанционного зондирования Земли (ДЗЗ), основанные на возможностях применения гиперспектральных (ГС) технологий. Отличительной особенностью регистрируемых при такой съёмке изображений является большое количество каналов в видимом, ближнем и коротковолновом инфракрасных диапазонах [1, 2]. Учитывая уникальность спектров поглощения различных веществ, регистрируемая информация потенциально позволяет определять не только тип наблюдаемых объектов, но и их состояние (например, содержание отдельных пигментов и влаги в растительном покрове). Это существенно увеличивает объём данных и, как следствие, сложность их передачи, хранения и обработки. В то же время не вся регистрируемая информация одинаково полезна. Многие исследования продемонстрировали свойство межканальной избыточности ГС-изображений [3]. Кроме того, спектральные сигнатуры могут подвергаться изменениям в зависимости от освещённости и атмосферных условий [4]. Это приводит к необходимости разрабатывать методики и технологии определения наиболее информативных спектральных каналов.

Наряду с этим в последние годы предпринимаются попытки использования преимуществ ГС-технологий при создании мобильных систем наблюдения, предназначенных для работы в полевых условиях. Трудность состоит в том, что традиционные ГС-камеры основаны на применении дисперсионного элемента, сканера и матричного приёмника [5]. Они сканируют объект целевой диафрагмой и используют первый порядок дифракции для разложения изображения в спектр. На каждом шаге сканирования регистрируется один срез ГС-изображения, поэтому время формирования полного изображения с помощью такой камеры исчисляется несколькими секундами или даже минутами. Отметим, что такой подход удобен при решении задач ДЗЗ, где сканирование организуется за счёт движения аппарата на орбите. Эти устройства непригодны в большинстве практических приложений, где камера или объекты наблюдения произвольно перемещаются в пространстве.

Ключевым нововведением последних лет стал отказ от необходимости применения дисперсионного элемента для разбиения входного излучения на набор полос с разными длинами волн. Решением стала идея нанесения узких спектральных фильтров непосредственно на поверхность высококачественного и одновременно серийно производимого КМОП-сенсора на уровне полупроводниковой пластины [6–10]. Данная технология получила название *filter-on-chip*. Всё это привело к появлению гиперспектрального фильтра, организованного «плиточным» образом, т. е. разделённого на равные прямоугольные секции, каждая из которых отвечает за свой узкий спектральный диапазон. Например, двухмегапиксельный сенсор CMOSIS CMV2000 вмещает 32 плиточные секции с разрешением 256×256 пикселей каждая. В итоге камера формирует изображение с разрешением 256×256 пикселей со скоростью около 30 кадр/с при дневном освещении и до 340 кадр/с при лучших условиях, применяемых, например, в машинном зрении. Камера чувствительна в видимом и ближнем ИК-диапазонах (600–1000 нм) с шириной каналов 12 нм. Следующим шагом развития данных технологий является фильтр мозаичного типа [11]. В этом случае мозаичный ГС-сенсор делится на группы пикселей, каждая из которых имеет определённый спектральный фильтр, и результирующее ГС-изображение формируется из соответствующих пикселей разных групп.

Перечисленные технологии делают ГС-камеры сравнительно доступными для множества применений: они достаточно компактны, легки и пригодны для использования в качестве систем наблюдения различного назначения. Такие системы могут быть приспособлены для конкретного применения путём определения необходимого количества и ширины спектральных полос, а также разрешения изображения в каждом диапазоне спектра. Выбор спектральных интервалов, их числа и расположения, как правило, производится на этапе проектирования систем и в процессе эксплуатации не изменяется [6–9], однако известны попытки создания фильтров с перенастраиваемыми характеристиками [10]. В ходе исследований изображающего фильтрового гиперспектрометра показано, что, несмотря на неидеальную функцию пропускания фильтра, в целом погрешность формирования спектрального распределения невелика и составляет не более 13 % [12].

В работах [13–15] при обработке крупноформатных ГС-изображений выполнено экспериментальное исследование эффективности ряда методов спектральной и спектрально-пространственной классификации типов растительности при различном количестве признаков. В результате показана возможность использования небольшого количества признаков (15–20 для природной зоны и 10–15 для городской застройки), сформированных с применением метода главных компонент и его различных модификаций [16, 17]. Это позволило уменьшить трудоёмкость вычислений на два порядка без существенного снижения точности классификации. Однако для формирования указанных признаков по-прежнему необходимо осуществлять регистрацию, передачу и хранение данных сотней спектральных каналов, поскольку результирующие признаки рассчитываются путём линейной комбинации всех исходных.

Целью данной работы является экспериментальное исследование возможности существенного уменьшения объёма регистрируемых данных за счёт выбора ограниченного количества наиболее информативных спектральных каналов при решении задачи классификации сельскохозяйственных культур. Исследования выполнены на примере обработки данных 220-канального авиационного гиперспектрального изображения, полученного в рамках программы AVIRIS на опытном полигоне Индиан Пайс [18].

Выбор информативной подсистемы признаков. Задача состоит в том, чтобы из N признаков на основе анализа обучающей выборки (набора пикселей с известными в результате наземных наблюдений классами) сформировать наиболее информативную подсистему, состоящую из n признаков ($n < N$). Это требует проверки $N!/(Nn)!n!$ альтернативных комбинаций, что при небольшом N может быть выполнено простым полным перебором. Однако рост количества признаков ведёт к экспоненциальному увеличению вычислительных затрат, что особенно принципиально при проектировании систем с настраиваемыми фильтрами.

Простейшим способом, позволяющим исключить необходимость полного перебора, является способ последовательного сокращения признаков (Del-алгоритм) [19]. При его применении поочерёдно исключается один из признаков и определяется информативность результирующих систем из $N - 1$ признаков. В качестве критерия информативности используется точность классификации обучающей выборки, которая рассчитывается как доля правильно классифицированных пикселей в процентах. Таким образом определяется наиболее информативная система из $N - 1$ признаков, и процедура повторяется до достижения n признаков.

Аналогичный подход использован в алгоритме последовательного добавления признаков (Ad-алгоритм) [20]. Он отличается от предыдущего лишь тем, что порядок проверки подсистем признаков начинается не с N -мерного, а с одномерных пространств. Вначале все N признаков проверяются на информативность. Для этого осуществляется классификация обучающей выборки по каждому признаку в отдельности и в информативную подсистему включается признак, давший наибольшую точность классификации. Затем к нему поочерёдно добавляется каждый из оставшихся признаков и выбирается наиболее информативная подсистема из двух признаков. Процесс повторяется до получения системы с требуемым количеством признаков.

Оба описанных алгоритма дают оптимальное решение на каждом шаге, но это не обеспечивает глобального оптимума. Для внесения элемента случайности во многих исследованиях применяются методы стохастической и эволюционной оптимизации (например, алгоритмы генетический (Genetic Algorithms — GA) и роя частиц (Particle Swarm Optimization — PSO) [21, 22]), действующие путём случайного подбора, комбинирования и вариации искомым параметров с использованием механизмов, аналогичных естественному отбору в природе.

В предлагаемой работе для ослабления влияния ошибок на первых шагах процедуры алгоритмом Ad набирается некоторое количество информативных признаков и затем часть из них исключается алгоритмом Del. Повторение этих процедур (алгоритм AdDel) продолжается до получения системы из требуемого количества признаков.

Необходимо отметить, что результирующий набор спектральных каналов зависит от применяемого метода классификации на этапе оценки информативности сформированных систем признаков на промежуточных шагах алгоритма. В данной работе такая оценка выполнялась методами максимального правдоподобия (Maximum Likelihood — ML) [23] и опорных векторов (Support Vector Machine — SVM) [24, 25]. Метод ML основан на оценке статистики второго порядка (ковариационная матрица) и для ГС-данных требует больших объёмов обучающих выборок (ОВ). Для корректной оценки объём обучающей выборки должен в десятки раз превосходить количество спектральных каналов. В ситуации, когда

объём ОБ ограничен, возможно получение вырожденных (сингулярных) ковариационных матриц. Метод SVM не применяет статистику второго порядка и может использоваться при ограниченном объёме ОБ. Однако SVM также имеет свои недостатки при его применении в наших целях. Во-первых, его точность классификации при большом количестве признаков и объёме ОБ несколько ниже, чем у ML. Во-вторых, он основан на итерационной процедуре проверки многих альтернативных решений для настраивания параметров разделяющей гиперповерхности и, как следствие, требует много процессорного времени и других вычислительных ресурсов. Таким образом, метод оценки информативности систем признаков чрезвычайно важен, его следует выбирать исходя из параметров обрабатываемых данных и имеющихся вычислительных ресурсов.

Подбор ширины спектральных каналов. После выбора спектральных каналов целесообразно определить их ширину. Наличие 220-канального ГС-изображения позволяет подобрать ширину спектральных каналов, обеспечивающую максимальную разделимость обучающей выборки. Для этого данные каждого отобранного канала усредняются с несколькими соседними и выполняется оценка информативности результирующей системы. Процедура повторяется для различного количества усредняемых каналов, и определяется то их количество, при котором достигается максимальная точность классификации данных обучающей выборки. Подбор ширины циклически повторяется для каждого канала при ширинах остальных каналов, выбранных ранее, и прекращается, когда они перестают изменяться.

Установлено, что представленный алгоритм приводит к разным результирующим комбинациям при различном выборе исходных ширин отобранных каналов.

Чтобы избежать ловушки локального оптимума, применяется случайный способ задания исходных ширин для отобранных каналов. Проверяется несколько случайных вариантов, и выбирается обеспечивающий при использовании процедуры подбора ширин лучший результат.

При применении указанных методов формирования систем признаков нет абсолютной уверенности в том, что они смогут найти глобальный оптимум, однако целью данной работы является демонстрация изложенного подхода, а не поиск способа выбора оптимальной системы признаков. Интересующимся способами выбора оптимальной системы признаков можно порекомендовать ознакомиться, например, с работами [26, 27].

Экспериментальные результаты. Экспериментальные исследования эффективности классификации данных на основе сокращённых подсистем признаков выполнены с применением крупноформатного ГС-изображения (рис. 1, *a*). Размер изображения 614×2677 пикселей, разрешение 20 м/пикс., число каналов 220 в диапазоне 0,4–2,5 мкм, по результатам наземных (подспутниковых) наблюдений изображение разбито на 58 классов (эталонная карта классов, рис 1, *b*). Среди них сельскохозяйственные культуры (в том числе 15 классов кукурузы и 18 классов сои, различающиеся методиками возделывания почвы), а также магистраль, железная дорога, лес, жилые постройки.

Для формирования информативных подсистем признаков использован фрагмент изображения размером 145×145 пикселей, содержащий 16 классов (рис. 1, *c, d*), 14 из которых представляют различные типы растительности, включая 3 класса кукурузы и 3 класса сои. В обучающую выборку было включено 25 % пикселей каждого класса, представленного на фрагменте.

В соответствии с алгоритмом AdDel в цикле осуществлялось формирование очередной подсистемы признаков. В качестве признаков на данном этапе использовались яркости спектральных каналов ГС-изображения. К сформированной на предыдущем цикле системе признаков поочерёдно добавлялись ранее неотобранные каналы, для каждой комбинации признаков выполнялись классификация ОБ указанного фрагмента и оценка точности классификации. На этой основе определялась подсистема, обеспечивающая максимальную

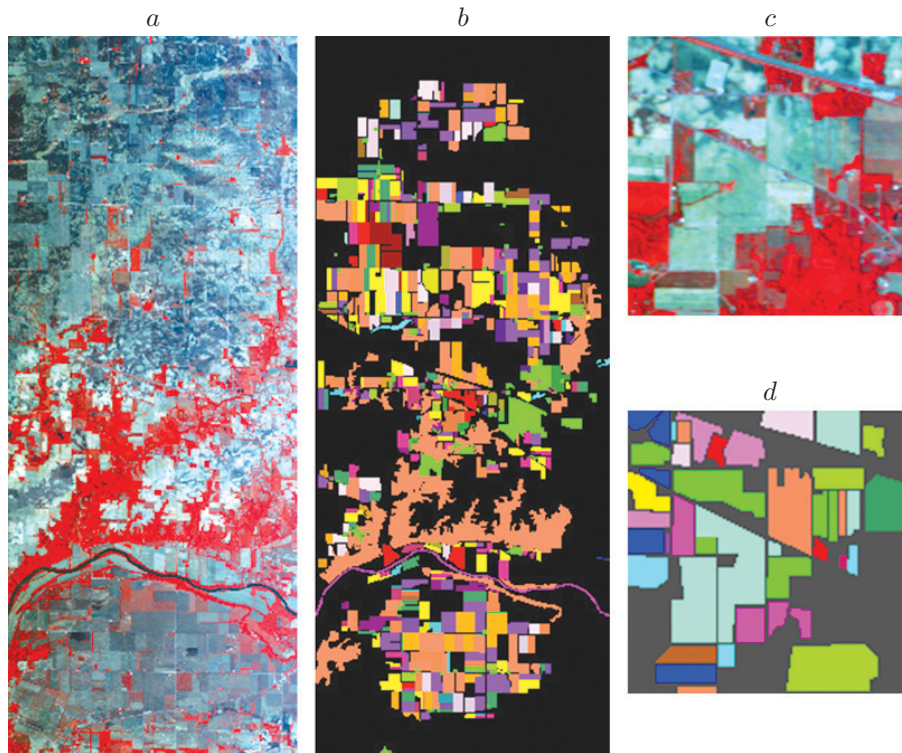


Рис. 1. Исходные данные Д33: *a* — RGB-композит крупноформатного ГС-изображения (каналы 40:20:10), *b* — эталонная карта классов изображения, *c* — RGB-композит фрагмента, *d* — эталонная карта классов фрагмента

Таблица 1

Подбор каналов алгоритмом AdDel

Каналы в порядке выбора										
ML	74	133	14	37	24	179	33	96	166	34
SVM	134	73	29	37	34	178	167	17	116	30
Каналы по возрастанию номеров										
ML	14	24	33	34	37	74	96	133	166	179
SVM	17	29	30	34	37	73	116	134	167	178

точность классификации при текущем количестве признаков. При этом три цикла наращивания системы признаков чередовались с одним циклом её сокращения до получения требуемого количества признаков.

В табл. 1 приведены номера 10 каналов, отобранных в результате выполнения указанной процедуры при оценке информативности систем признаков с применением методов классификации ML и SVM. На рис. 2 сформированные подсистемы объёмом 10 и 20 признаков представлены для наглядности на фоне спектра одного из подклассов сои. Видно, что наборы каналов для методов ML и SVM не идентичны, но по своему характеру очень близки. Как и следовало ожидать, наиболее информативным для разделения типов растительности является спектральный диапазон приблизительно от 0,45 до 0,76 мкм [28] (каналы номер 23–37). Во всех случаях в данном диапазоне плотность выбранных каналов максимальна.

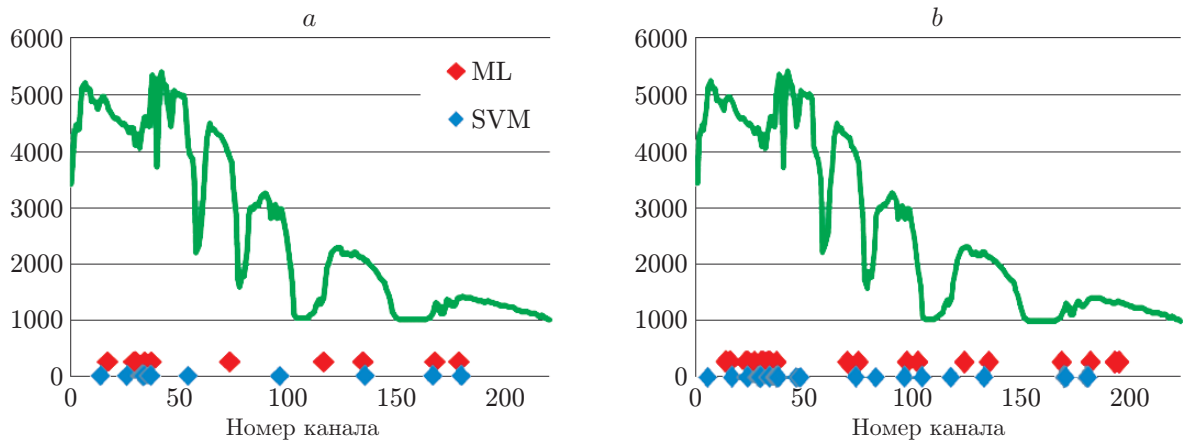


Рис. 2. Спектральные каналы, отобранные алгоритмом AdDel из 220 исходных при применении ML и SVM для оценки информативности систем признаков:
a — 10 каналов, *b* — 20 каналов

В данном диапазоне находится максимум отражения зелёной растительности в видимой области ($\sim 0,54$ мкм), а также наблюдается резкий рост коэффициента отражения (приблизительно с $0,70$ мкм) в ближней ИК-области спектра. Эти эффекты обусловлены относительно низким уровнем поглощения хлорофилла (максимум поглощения приходится на полосы $0,45$, $0,65$ мкм), содержащегося в здоровом листе.

Для каждого типа растительности характерно своё содержание хлорофилла (и других пигментов), и это приводит к появлению определённых особенностей в спектре поглощения и отражения в данной области длин волн. Так, если растение повреждено и находится в состоянии стресса, образование хлорофилла значительно уменьшается, что приводит к уменьшению поглощения в указанных полосах. Этот факт позволяет определять участки растительного покрова, подвергшиеся неблагоприятному воздействию [29].

После выбора заданного количества наиболее информативных признаков для каждого из них осуществлялся подбор спектральной ширины (усреднением данных соседних каналов), обеспечивающей максимально эффективную разделимость ОВ. Подбор ширины осуществлялся в два этапа. На первом определялась ширина подбираемого канала, обеспечивающая максимальную точность классификации обучающей выборки, при ширине всех остальных каналов, заданных определённым образом. На втором этапе процедура подбора ширины циклически повторялась для каждого канала при ширинах остальных каналов, выбранных ранее, и прекращалась, когда они переставали изменяться. Как уже отмечалось, указанная процедура выполнялась для нескольких вариантов исходного задания ширин. В качестве результирующего набора использовался набор ширин, обеспечивающий максимальную эффективность классификации обучающей выборки.

В табл. 2 приведены ширины спектральных каналов, полученные в результате применения предложенной процедуры при задании минимальных исходных значений для случая выбора 10 каналов (оценка информативности выполнена методом классификации ML). Здесь и далее численное значение ширины определяет число соседних каналов, объединяемых с каналом, отобранным алгоритмом AdDel: значение 0 — учитываются данные только отобранного канала, значение n — усредняются данные $2n + 1$ каналов (n меньших и n больших по номеру).

В табл. 3 представлены результирующие комбинации ширин и их информативность при различном выборе исходных ширин соответствующих каналов.

Отметим, что даже достаточно близкие между собой исходные комбинации нередко дают разные результаты (в приведённом примере пятая и шестая строки). При этом тре-

Таблица 2

Подбор ширины десяти отобранных алгоритмом AdDel каналов

Номер канала	74	133	14	37	24	179	33	96	166	34
Исходная ширина	0	0	0	0	0	0	0	0	0	0
Ширина (1 этап)	5	9	3	10	3	0	0	1	0	0
Ширина (2 этап)	8	2	4	6	3	0	6	10	5	1

Таблица 3

Подбор ширины десяти отобранных алгоритмом AdDel каналов при различных исходных ширинах

Исходная комбинация ширин 10 отобранных каналов	Точность разделения ОБ при исходных ширинах	Результирующая комбинация ширин	Точность разделения ОБ при результирующих ширинах
0, 0, 0, 0, 0, 0, 0, 0, 0, 0	84,83	8, 2, 4, 6, 3, 0, 6, 10, 5, 1	88,02
1, 1, 1, 1, 1, 1, 1, 1, 1, 1	85,15	8, 4, 4, 7, 2, 0, 8, 7, 7, 1	88,09
10, 2, 4, 6, 2, 2, 7, 8, 1, 1	87,54	9, 2, 6, 6, 2, 3, 8, 7, 3, 1	88,21
9, 4, 6, 8, 9, 2, 9, 7, 0, 1	86,64	9, 2, 6, 6, 2, 3, 8, 7, 3, 1	88,21
5, 9, 3, 10, 1, 1, 1, 1, 1, 1	86,25	9, 2, 6, 10, 1, 5, 6, 10, 2, 1	87,23
5, 9, 3, 10, 3, 0, 0, 1, 0, 0	85,93	7, 10, 0, 4, 2, 0, 2, 1, 4, 1	86,88
8, 1, 10, 4, 1, 1, 2, 1, 7, 6	84,75	9, 6, 2, 6, 2, 0, 6, 10, 8, 1	87,94
1, 2, 3, 4, 5, 6, 7, 8, 9, 10	83,10	10, 9, 2, 7, 1, 9, 4, 6, 1, 1	87,23
5, 5, 5, 5, 5, 5, 5, 5, 5, 5	82,99	9, 10, 6, 7, 3, 0, 6, 10, 4, 1	87,94
3, 4, 4, 3, 2, 1, 0, 0, 1, 2	84,72	9, 2, 6, 6, 2, 3, 8, 7, 3, 1	88,21
3, 3, 3, 3, 3, 3, 3, 3, 3, 3	83,89	9, 7, 10, 9, 1, 4, 5, 5, 3, 1	87,23
2, 2, 2, 2, 2, 2, 2, 2, 3, 2	84,91	2, 10, 4, 1, 1, 4, 8, 5, 2, 1	87,31

тъя, четвёртая и десятая комбинации привели к одинаковому результирующему набору ширин, обеспечивающему максимальную точность разделения обучающей выборки. Этот набор и был использован в последующих исследованиях.

Сформированные системы из 10, 20 и 40 признаков (алгоритмом AdDel и AdDel с подбором ширины каналов) в дальнейшем применялись при классификации фрагмента изображения. Результирующие точности приведены в табл. 4. Здесь же для сравнения представлены данные, полученные при формировании системы признаков регулярным прореживанием, а также методами главных компонент (РСА) и главных компонент с предварительной нормализацией шума (MNF) [30]. Из таблицы следует, что применяемый метод формирования подсистем признаков имеет существенное преимущество по сравнению с регулярным прореживанием и близок по эффективности к методам на основе анализа главных компонент (в частности MNF). Однако, как уже указывалось, его несомненным достоинством является возможность снижения требований к регистрирующей аппаратуре, пропускной способности каналов передачи данных и требуемой вычислительной производительности.

Следует отметить, что максимальная точность классификации тестовой выборки фрагмента достигается при применении 20 признаков. При дальнейшем увеличении количества признаков точность разделения обучающей выборки возрастает, однако этот

Таблица 4

Классификация фрагмента изображения методом ML (по ОВ) с применением подсистем признаков

Количество каналов	Прореживание	PCA	MNF	AdDel	AdDel + подбор ширины
10 каналов	74,7 (77,7)	80,0 (82,8)	86,3 (88,1)	79,7 (84,2)	84,4 (88,2)
20 каналов	79,0 (85,9)	85,9 (90,6)	88,8 (92,2)	84,7 (91,9)	87,7 (93,1)
40 каналов	81,3 (95,8)	85,2 (95,9)	87,8 (96,5)	82,9 (97,2)	86,4 (97,7)

Таблица 5

Классификация полного изображения методом ML с применением подсистем признаков (слияние классов кукурузы и сои)

Количество каналов	Прореживание	PCA	MNF	AdDel	AdDel + подбор ширины
10 каналов	57,8	63,2	67,6	62,7	64,9
20 каналов	63,1	69,6	72,4	65,0	70,1
40 каналов	68,7	71,6	74,3	68,9	72,4
100 каналов	74,3	74,8	76,5	—	—

эффект, очевидно, связан с переобучением и не имеет практического значения, поскольку точность классификации тестовой выборки начинает снижаться, что объясняется недостаточной представительностью ОВ. Так, при одном и том же объёме выборки чем выше размерность признакового пространства, тем меньше обоснованность получаемых статистических выводов.

При классификации полного изображения с применением сформированных (изложенным способом на основе данных ОВ фрагмента) систем из 10 и 20 признаков достигнута точность, превышающая точность классификации в системе, полученной регулярным прореживанием (более чем на 7 %) и на основе PCA, но несколько уступающая полученной в системе признаков на основе MNF (табл. 5).

Заключение. Путём численного моделирования продемонстрирована возможность определения сокращённых подсистем признаков, состоящих из небольшого количества наиболее информативных гиперспектральных каналов (их положения и ширины), на основе их последовательного добавления-сокращения.

В ходе исследований экспериментально показано, что регистрация и обработка данных в 10 спектральных каналах, выбранных в соответствии с изложенной методикой по фрагменту ГС-изображения, позволяет получить точность классификации крупноформатного изображения при решении задачи мониторинга сельскохозяйственных культур не хуже, чем для систем признаков, сформированных с применением метода главных компонент. При этом трудоёмкость требуемых вычислений существенно уменьшается. Выбор спектральных интервалов, их числа и расположения производится на этапе подготовки к решению определённых классов задач и в процессе эксплуатации не изменяется. Такой подход приводит к повышению эффективности решения целевых задач вследствие того, что представляется возможным достаточно полно учесть характерные особенности объектов исследования и условия наблюдения в каждом конкретном случае.

Полученные результаты свидетельствуют, что при малых объёмах обучающих выбо-

рок (эксперименты с фрагментом изображения) применение более 20 признаков не приводит к увеличению точности классификации. В случае расширения ОВ (эксперименты с полным изображением) использование большего количества признаков позволяет несколько повысить точность классификации, однако ведёт к существенному увеличению аппаратных ресурсов и вычислительных затрат, что для большинства практических приложений не целесообразно. Это даёт возможность перейти от применения дорогостоящей и сложной гиперспектральной аппаратуры, которое оправдано при проведении исследований из космического и околоземного пространства, к разработке и созданию малогабаритных приборов дистанционной диагностики с небольшим количеством специально выбранных под конкретные задачи признаков с целью их широкого практического применения.

Одним из путей дальнейшего развития является отказ от датчиков с фиксированными параметрами и переход к адаптивным системам ГС-наблюдения (например, с применением акустооптических фильтров или электроуправляемых интерферометров Фабри — Перо). К числу технических проблем, которые должны быть решены при создании нового поколения систем, относится разработка и обеспечение новых, адаптивных режимов функционирования аппаратуры. При этих режимах выбор и настройка информационных параметров производится под конкретную задачу (условия наблюдения) в реальном масштабе времени. К числу настраиваемых информационных параметров можно отнести пространственное и спектральное разрешения, разрядность квантования сигнала. Реализация перспективных режимов функционирования аппаратуры позволит существенно расширить эксплуатационные показатели гиперспектральных систем, тем самым поднимая уровень решения задач наблюдения и классификации на качественно новую ступень.

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. **Шипко В. В.** Фильтрация шума на гиперспектральных изображениях // Автометрия. 2020. 56, № 1. С. 23–32. DOI: 10.15372/AUT20200103.
4. **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.
5. **Виноградов А. Н., Егоров В. В., Калинин А. П. и др.** Линейка гиперспектральных сенсоров оптического диапазона. 2015. 20 с. (Препр. /ИКИ РАН; 2015-2176).
6. **Tack N., Lambrechts A., Soussan S., Haspeslagh L.** A compact, high-speed, and low-cost hyperspectral imager // Proc. SPIE. 2012. **8266**. 82660Q.
7. **Geelen B., Tack N., Lambrechts A.** A snapshot multispectral imager with integrated, tiled filters and optical duplication // Proc. SPIE. 2013. **8613**. 861314.
8. **Gat N.** Imaging spectroscopy using tunable filters: A review // Proc. SPIE. 2000. **4056**. P. 50–64.
9. **Correia J. H., Bartek M., Wolfenbuttel R. F.** High-selectivity single-chip spectrometer in silicon for operation in visible part of the spectrum // IEEE Transactions on Electron Devices. 2000. **47**, N 3. P. 553–559.
10. **Jayapala M., Lambrechts A., Tack N. et al.** Monolithic integration of flexible spectral filters with CMOS image sensors at wafer level for low cost hyperspectral imaging. 2013. URL: http://www.imagesensors.org/Past%20%Workshops/2013%20Workshop/2013%20Papers/07-02_053jayapala.pdf. 2015 (дата обращения: 15.05.2020).

11. **Шведов А.** Гиперспектральные сенсоры компании IMEC. Решения для высококачественного спектрального анализа. URL: <https://www.npk-photonica.ru/giperspektralnye-sensory-kompanii-imes-pdf163406.pdf> (дата обращения: 15.05.2020).
12. **Скиданов Р. В., Морозов А. А., Порфирьев А. П., Бланк В. А.** Изображающий спектрометр на основе дискретного интерференционного фильтра // Компьютерная оптика. 2015. **39**, № 5. С. 716–720. DOI: 10.18287/0134-2452-2015-39-5-716-720.
13. **Борзов С. М., Гурьянов М. А., Потатуркин О. И.** Исследование эффективности классификации трудноразличимых типов растительности по гиперспектральным данным // Компьютерная оптика. 2019. **43**, № 3. С. 464–473. DOI: 10.18287/2412-6179-2019-43-3-464-473.
14. **Борзов С. М., Потатуркин А. О., Потатуркин О. И., Федотов А. М.** Исследование эффективности классификации гиперспектральных спутниковых изображений природных и антропогенных территорий // Автометрия. 2016. **53**, № 1. С. 3–14. DOI: 10.15372/AUT20160101.
15. **Борзов С. М., Потатуркин О. И.** Исследование эффективности спектрально-пространственной классификации данных гиперспектральных наблюдений // Автометрия. 2017. **54**, № 1. С. 32–42. DOI: 10.15372/AUT20170105.
16. **Fodor I.** A survey of dimension reduction techniques // Technical Report UCRL-ID-148494. Oakland: University of California, 2002. 26 p.
17. **Пестунов И. А., Мельников П. В.** Метод главных компонент и его модификации в задачах классификации гиперспектральных данных // Интерэкспо Гео-Сибирь. 2015. **4**, № 2. С. 45–50.
18. **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.
19. **Merill T., Green O. M.** On the effectiveness of receptors in recognition systems // JRE Trans. Inform. Theory. 1963. **JT**, N 9. P. 11–17.
20. **Ghamisi P., Benediktsson J. A.** Feature selection based on hybridization of genetic algorithm and particle swarm optimization // IEEE Geos. and Remote Sens. Lett. 2015. **12**, N 2. P. 309–313.
21. **Beasley D., Bull D. R., Martin R. R.** An overview of genetic algorithms // University Computing. 1993. N 2. P. 58–69.
22. **Барабаш Ю. Л., Варский Б. В., Зиновьев В. Т. и др.** Автоматическое распознавание образов. Киев: КВАИУ, 1964. 168 с.
23. **Richards J. A.** Remote sensing digital image analysis. Berlin: Springer-Verlag, 1999. 240 p.
24. **Cristianini N.** An introduction to support vector machines and other kernel-based learning methods. Cambridge University Press, 2000. 189 p.
25. **Chang C. C., Lin C. J.** LIBSVM: A library for support vector machines // ACM Trans. Intell. Syst. and Technol. 2011. **2**, N 3. P. 1–27. URL: <https://doi.org/10.1145/1961189.1961199> (дата обращения: 15.05.2020).
26. **Загоруйко Н. Г., Елкина В. Н., Лбов Г. С., Емельянов С. В.** Пакет прикладных программ ОТЭКС. М.: Финансы и Статистика, 1986. 160 с.
27. **Елкина В. Н., Загоруйко Н. Г., Темиркаев В. С.** Алгоритмы направленного таксономического поиска информативных подсистем признаков (НТПП) // Вычислительные системы: Сб. тр. ИМ СО АН СССР. Новосибирск, 1974. Вып. 59. С. 49–70.
28. **Дистанционное зондирование: количественный подход** / Под ред. А. С. Алексеева. М.: Недра, 1983. 415 с.
29. **Дубровская О. А., Гурова Т. А., Пестунов И. А.** Обнаружения болезней на посевах пшеницы по данным гиперспектральной съёмки // Обработка пространственных данных

в задачах мониторинга природных и антропогенных процессов (SDM-2019): Сб. тр. всерос. конф. с междунар. участием. Новосибирск, 2019. С. 497–500.

30. **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. and Remote Sens. 1988. **26**, N 1. P. 65–74.

Поступила в редакцию 15.05.2020

После доработки 22.05.2020

Принята к публикации 08.06.2020
