

Классификация гиперспектральных спутниковых изображений по эталонным участкам территории

В.А. Федосеев^{1,2}

¹Институт систем обработки изображений РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

²Самарский национальный исследовательский университет имени академика С.П. Королева, Московское шоссе 34, Самара, Россия, 443086

Аннотация. Работа посвящена выбору технологии и конкретных алгоритмических решений для тематической классификации гиперспектральных спутниковых изображений при условии обучения по небольшому объёму данных, подбираемых вручную из локализованных эталонных участков самих изображений. Ситуация, требующая применения такой технологии, может быть вызвана недостатком данных о съёмке и анализируемой территории и нередко возникает на практике. Выбранная технология включает этапы поэлементной и пространственной предобработки анализируемого изображения, его классификации с учётом пространственных и спектральных факторов, а также пространственной постобработки полученных результатов. Экспериментальные исследования показали существенное снижение качества классификации в рассматриваемых условиях. В результате экспериментов наилучшим образом показало себя решение, основанное на объединении результатов поэлементной классификации с сегментацией на основе метода *k-means++* и заливки связных областей, дополненное нелинейными методами пред- и постобработки. Полученные в работе выводы подкреплены результатами сравнительных исследований различных методов и алгоритмов на каждом этапе классификации.

1. Введение

1.1. Постановка задачи

При решении задач тематического анализа территории не всегда существует возможность использовать космические снимки, наилучшим образом подходящие для конкретной задачи. Это может быть обусловлено финансовыми факторами (не всегда существует возможность купить наилучшие снимки), а также организационными (нет доступа к снимкам за анализируемый период в прошлом или нет возможности ожидать исполнения заказа на съёмку), природными (высокая облачность в момент заказанной съёмки) и некоторыми другими. В такой ситуации возникает необходимость использовать любые доступные снимки территории, относящиеся к интересующему периоду, в том числе и те, для которых отсутствует полная информация об условиях съёмки и параметрах камеры.

В качестве примера рассмотрим следующий случай. Пусть необходимо произвести тематическую классификацию участка местности, содержащей известные поверхностные объекты, чья спектральная отражательная способность известна по имеющейся библиотеке

спектров материалов. Однако для анализа используется гиперспектральный снимок, который либо не подвергся атмосферной коррекции, либо длины волн его каналов неизвестны или известны неточно. В результате использование спектров из библиотеки в качестве обучающих данных приведёт к неточным результатам.

В таких случаях исследователь, знающий хотя бы некоторые объекты на местности, мог бы отметить на снимке примеры интересующих его классов и использовать их в качестве обучающей выборки для решения задачи тематической классификации всего снимка. Таким образом, задача сводится к тому, чтобы выбрать наилучший метод классификации в условиях следующих ограничений:

- гиперспектральные данные рассматриваются «как есть», то есть без семантической информации о каналах, параметрах съёмки и пр.;
- относительно имеющихся данных неизвестно, была ли проведена их атмосферная коррекция, то есть метод должен работать хорошо в обоих случаях;
- обучающая выборка формируется из самих отсчётов снимка, причём геометрически локализованных для каждого отдельного класса в небольшой области (пользователь не может тратить большое количество времени на поиск различных обучающих примеров на всём изображении);
- ограниченный объём обучающих данных (вплоть до нескольких десятков примеров на каждый класс).

1.2. Обзор существующих решений

Базовый подход к классификации гиперспектральных данных дистанционного зондирования Земли (ДЗЗ), – поэлементная классификация, – состоит в том, что каждый пиксель изображения классифицируется отдельно на основании его спектральных характеристик. Таким образом, пространственные связи между пикселями теряются, но зато задача сводится к классической задаче классификации одномерной выборки данных. Очевидно, результат поэлементной классификации может быть улучшен за счёт использования пространственной информации, а также информации о распределении всех классифицируемых данных в пространстве признаков. Большинство известных алгоритмов, учитывающих эти факторы, основаны на кластеризации отсчётов изображения или их сегментации с последующей агрегацией полученных результатов с результатами попиксельной классификации [1, 2]. Так, в статье [2] сравниваются 4 различных метода спектрально-пространственной классификации, основанных на обработке скользящим окном и на сегментации. В работе [1] применяется кластеризация методом *k-means++* с последующим отысканием пространственно-связных сегментов, а итоговый выбор классов осуществляется голосованием по полученным сегментам.

В настоящей работе предлагается технология классификации гиперспектральных изображений, являющаяся результатом анализа ряда работ и состоящая из нескольких этапов. Выбор алгоритмического решения, применяемого на каждом этапе, производится на основе сравнительных экспериментальных исследований существующих методов и алгоритмов при условиях, обусловленных рассматриваемой задачей.

2. Подготовка экспериментов

Поскольку работа носит экспериментальный характер и выбор тех или иных алгоритмических решений осуществляется на основе экспериментальных исследований, то прежде всего следует конкретизировать важнейшие параметры экспериментов.

Для сравнительного анализа различных стратегий классификации при формировании обучающей выборки использовались следующие варианты числа отсчётов каждого класса: 15; 50 и 100 отсчётов; а также 1, 5, 10 и 25 процентов от всех экземпляров каждого класса. Также рассматривались два способа формирования обучающей выборки: случайный (среди всех экземпляров каждого класса по всему изображению) и локализованный (множество соседних экземпляров каждого класса).

Для анализа эффективности алгоритмов тематической классификации при отсутствии атмосферной коррекции требовались пары снимков (до и после коррекции) и соответствующие им классы наземных объектов. Поскольку в свободном доступе таких данных найти не удалось, в ходе работ осуществлялось моделирование атмосферных искажений на открытых данных согласно стандартному уравнению переноса излучения в полной (нелинейной) форме модели MODTRAN [3-5]. Для этого использовалось изображение Indian Pines размерами 145×145, снятое аппаратом AVIRIS с разрешением 200 каналов; размеченные данные содержат 10250 экземпляров, отнесённых к 16 классам подстилающей поверхности. Кроме того, исследования проводились и на изображении Pavia University, однако ввиду ограничений на объём статей, полученные результаты не представлены в данной работе. В целом они согласуются с результатами для Indian Pines.

В качестве показателя качества классификации во всех экспериментах применялась точность (accuracy), равная доле правильно классифицированных пикселей из числа всех размеченных пикселей изображения.

3. Технология классификации гиперспектральных изображений и её основные этапы

Выбранная технология классификации состояла из следующих этапов:

1. Поэлементная предобработка входных данных.
2. Пространственная предобработка входных данных.
3. Классификация с учётом кластерной структуры данных и пространственной информации, включающая следующие компоненты:
 - 3.1. Классификация одного вектора признаков (применяемая поэлементно для всех входных данных или для средних/медиан кластеров).
 - 3.2. Учёт кластерной структуры данных в пространстве признаков.
 - 3.3. Учёт пространственных связей во входных данных.
4. Пространственная постобработка результатов классификации.

Далее в последующих разделах будут детально рассмотрены и исследованы алгоритмы, применяемые на каждом из этапов. Однако в первую очередь мы ограничились одним методом поэлементной классификации – SVM с радиальной базисной функцией (SVM-RBF). Такой выбор обусловлен тем, что в ряде работ [1-2, 6] отмечалось высокое качество классификации гиперспектральных изображений с его помощью, а также результатами предварительно проведённых исследований.

Таблица 1. Сравнение точности поэлементной классификации при различных способах понижения размерности.

Метод понижения размерности	Пиксели			Процент площади			
	15	50	100	1	5	10	25
Локализованная обучающая выборка							
PCA	0.445	0.528	0.605	0.469	0.521	0.596	0.708
MNF	0.456	0.497	0.598	0.466	0.512	0.564	0.708
NAPC	0.481	0.536	0.610	0.491	0.538	0.585	0.711
NAPC+PCA	0.494	0.571	0.618	0.498	0.570	0.612	0.737
Случайно сформированная обучающая выборка							
PCA	0.596	0.688	0.742	0.547	0.733	0.763	0.846
MNF	0.603	0.694	0.775	0.601	0.722	0.768	0.848
NAPC	0.612	0.697	0.750	0.590	0.727	0.765	0.841
NAPC+PCA	0.603	0.730	0.788	0.598	0.759	0.812	0.867

Для поэлементной предобработки входных данных рассматривались следующие методы: метод главных компонент (Principal Component Analysis, PCA), Minimum Noise Fraction Transform (MNF) [7], Noise-Adjusted Principal Components Transform (NAPC) [8] и

последовательное применение NAPC и PCA. При этом во всех случаях оставлялись 20 признаков, используемых для дальнейшей классификации, что является компромиссом между качеством классификации и скоростью работы. В таблице 1 представлены результаты сравнения различных методов предобработки. Полученные результаты отчётливо показывают преимущество варианта NAPC+PCA, который и использовался при проведении последующих экспериментов.

4. Учёт кластерной структуры данных и пространственной информации

4.1. Описание методов

В ходе решения задачи использовались два метода кластеризации - Mean Shift и k-means++.

Mean shift («сдвиг среднего») – алгоритм кластеризации, предложенный в [9]. В данном алгоритме ищутся локальные максимумы ядерной оценки плотности распределения данных, исходя из предположения, что они соответствуют центрам искоемых кластеров. Существенными преимуществами данного алгоритма являются отсутствие предположений о форме кластеров и законе распределения, а также автоматический способ определения числа кластеров.

Алгоритм k-means++ [10] является расширением стандартного алгоритма k-средних (k-means) с усовершенствованным вариантом выбора начального приближения. В отличие от Mean Shift, этот алгоритм принимает на вход фиксированное число кластеров.

В ходе исследований рассматривались также варианты обоих алгоритмов в форме сегментации. Для этого после кластеризации на индексной матрице запускался поиск связанных областей, относящихся к одному кластеру. Благодаря этому осуществлялось дополнительное разбиение данных ещё и по пространственному признаку.

В работах [1, 2] рассматриваются два способа объединения результатов кластеризации (или сегментации) с результатами классификации. Оба они основаны на едином принципе, согласно которому все пиксели, принадлежащие к одной области (сегменту или кластеру) должны быть отнесены к одному тематическому классу. В первом способе выполняется голосование большинства, то есть для каждой области P рассчитывается статистика результатов поэлементной классификации, и класс, к которому отнесено наибольшее число точек данной области, выбирается для всей области P . Второй способ отличается тем, что по векторам признаков из каждой области: $y_i \in P$, – выполняется расчёт единого вектора признаков u , являющегося их медианой, а далее осуществляется его классификация, и полученный результат применяется ко всем пикселям рассматриваемого сегмента (кластера) P .

4.2. Результаты экспериментов

В настоящем подразделе мы приведём результаты исследования различных методов и их параметров, которые могут применяться для улучшения поэлементной классификации за счёт использования кластерной структуры данных или пространственных связей. В таблице 2 приведены результаты данного исследования в том же формате, что и результаты, отражённые в таблице 1. Исследование проводилось при локализованном способе формирования обучающей выборки. Следует также отметить, что для экономии места среди двух способов объединения (агрегации) кластеризации/сегментации и классификации (голосование большинства и классификация медиан) в каждом конкретном случае для таблицы выбирался тот, который в среднем обеспечивает более высокие показатели точности. В таблице 2 и далее курсивом выделены результаты поэлементной классификации, приводящиеся для сравнения. Полужирным отмечены наибольшие результаты по столбцу, подчёркиванием – результаты, близкие к наибольшим.

Отметим основные выводы, которые можно сделать на основе анализа полученных результатов. При локализованном способе формирования обучающей выборки рассмотренные методы позволяют улучшить результаты поэлементной классификации, хотя и не радикально. При этом кластеризация без сегментации не приводит к значительным улучшениям. Более того, зачастую поэлементная классификация выигрывает у классификации с кластеризацией без

учёта пространственных факторов. Также можно отметить, что k-means++ чаще позволяет добиться более высоких показателей, нежели Mean Shift, что в совокупности с его более высокой скоростью позволяет отдать ему предпочтение. Что касается методов агрегации, то здесь нельзя сделать однозначного вывода – в разных случаях лучше работают разные методы.

Таблица 2. Сравнение точности классификации при различных способах кластеризации и сегментации (локализованный способ формирования обучающей выборки).

Метод кластеризации	Тип	Метод агрегации	С	Пиксели			Процент площади			
				15	50	100	1	5	10	25
– (поэлементная)	–	–	–	0.494	0.571	0.618	0.498	0.570	0.612	0.737
k-means++	Кластеризация	Голосование	100	0.449	0.487	0.515	0.474	0.498	0.495	0.582
k-means++	Кластеризация	Голосование	400	0.486	0.552	0.571	0.502	0.548	0.571	0.645
Mean Shift	Кластеризация	Медиана	3550	<u>0.496</u>	0.565	0.584	0.488	0.563	0.573	0.667
Mean Shift	Кластеризация	Голосование	450	0.437	0.452	0.446	0.454	0.456	0.455	0.491
k-means++	Сегментация	Голосование	3000	0.511	0.594	0.601	0.493	0.591	0.597	0.759
k-means++	Сегментация	Медиана	6000	<u>0.502</u>	0.593	0.635	0.501	<u>0.580</u>	<u>0.618</u>	<u>0.747</u>
Mean Shift	Сегментация	Медиана	8400	0.491	<u>0.577</u>	0.637	0.497	0.570	0.621	<u>0.750</u>
Mean Shift	Сегментация	Голосование	4500	0.434	0.521	0.550	0.453	0.509	0.515	0.639

Важным вопросом, который необходимо было прояснить в ходе решения поставленной задачи, являлась эффективность работы рассматриваемых методов на данных, не подвергавшихся атмосферной коррекции. В таблице 3 приведены сравнительные результаты работы попиксельной классификации и варианта, показавшего себя наилучшим образом в таблице 2, для данных, на которых выполнено моделирование атмосферных искажений. Легко заметить, что точность при этом оказалась даже чуть выше, чем на исходных данных. Это может объясняться операцией пространственного усреднения, применяемого в модели MODTRAN [3-5], что неявно обеспечивает дополнительный учёт пространственной информации. Учитывая полученные результаты, можно прийти к выводу о том, что допустимо для поиска наилучшего алгоритма использовать скорректированные данные. Поэтому в дальнейшем не будем приводить для сравнения результаты на модельных данных.

Таблица 3. Сравнение точности классификации на скорректированных и атмосферно-искажённых данных (локализованный способ формирования обучающей выборки).

Метод кластеризации	Тип	Метод агрегации	С	Пиксели			Процент площади			
				15	50	100	1	5	10	25
Классификация исходных (скорректированных) данных										
– (поэлементная)	–	–	–	0.494	0.571	0.618	0.498	0.570	0.612	0.737
k-means++	Сегментация	Голосование	3000	0.511	0.594	0.601	0.493	0.591	0.597	0.759
Классификация атмосферно-искажённых данных (моделирование)										
– (поэлементная)	–	–	–	0.500	0.591	0.642	0.514	0.570	0.631	0.765
k-means++	Сегментация	Голосование	4500	0.509	0.600	0.651	0.522	0.577	0.629	0.773

Рассмотрим также для сравнения результаты исследования различных алгоритмов, полученные при случайном способе формирования выборки. Они отражены в таблице 4.

Таблица 4. Сравнение точности классификации при различных способах кластеризации и сегментации (псевдослучайный способ формирования обучающей выборки).

Метод кластеризации	Тип	Метод агрегации	С	Пиксели			Процент площади			
				15	50	100	1	5	10	25
– (поэлементная)	–	–	–	0.603	0.730	0.788	0.598	0.759	0.812	0.867
k-means++	Кластеризация	Голосование	100	0.460	0.540	0.560	0.538	0.599	0.595	0.590
k-means++	Кластеризация	Голосование	400	0.553	0.667	0.683	0.582	0.675	0.692	0.705
Mean Shift	Кластеризация	Медиана	3550	0.564	0.670	0.679	0.529	0.688	0.706	0.728
Mean Shift	Кластеризация	Голосование	450	0.394	0.478	0.494	0.409	0.523	0.545	0.546
k-means++	Сегментация	Голосование	3000	<u>0.634</u>	0.757	<u>0.821</u>	0.624	0.791	0.830	<u>0.880</u>
k-means++	Сегментация	Медиана	6000	0.645	<u>0.739</u>	0.835	<u>0.622</u>	<u>0.780</u>	<u>0.827</u>	0.886
Mean Shift	Сегментация	Медиана	8400	0.629	<u>0.752</u>	<u>0.815</u>	0.600	0.767	<u>0.822</u>	<u>0.880</u>
Mean Shift	Сегментация	Голосование	4500	0.598	0.627	0.659	0.521	0.704	0.763	0.808

Как можно заметить из таблицы 4, такой способ формирования выборки существенно увеличивает точность. Поэтому если есть возможность у пользователя разметить больше областей в пространственно удалённых друг от друга фрагментах анализируемого снимка, не стоит недооценивать важность этой работы. Также можно заметить, что кластерные методы в таком случае работают однозначно хуже поэлементных, таким образом, их применение в данном случае смысла не имеет. Однако использование методов сегментации по-прежнему позволяет добиться лучших результатов, и те же алгоритмы показали себя наилучшим образом.

5. Методы предварительной и финальной обработки данных, улучшающие качество классификации

В работе [2] отмечается, что пространственная предобработка входных данных (в частности, медианная фильтрация) может также повышать точность поэлементной классификации и использоваться вместо сегментации. Здесь следует добавить, что ничего не препятствует также использовать данную процедуру не вместо, но наряду с сегментацией. Отчасти справедливость тезисов работы [2] подтвердило применение процедур классификации на данных, подвергшихся моделированию атмосферных искажений (см. табл. 3), поскольку эти данные подвергаются в том числе обработке низкочастотным фильтром. Таким образом, целесообразно исследовать влияние медианной фильтрации исходных данных на результаты.

Помимо предобработки, важную роль играет также пространственная постобработка результатов классификации. Как правило, в этой роли выступает какая-либо нелинейная процедура коррекции данных в скользящем окне. Так, в частности, в работе [1] используется следующий вариант: для каждого положения окна определяется наиболее часто встречающийся класс пикселей, попадающих в это окно, а также число таких пикселей L . Если центр окна отнесён к классу, отличному от класса большинства, и L превышает некоторый порог T , то центральной точке назначается метка класса большинства.

Помимо этого алгоритма, на практике целесообразно применять также переклассификацию сегментов малой площади. Минимально допустимый размер площади задаётся параметрически

и зависит от разрешения исходных данных и содержания снимка, поэтому несмотря на безусловную важность, в данной работе эта процедура не исследовалась.

В таблицах 5–6 представлены результаты исследования методов пред- и постобработки. В качестве базовых алгоритмов классификации использовались:

- поэлементная классификация;
- сегментация с использованием k-means++ с голосованием большинства с наибольшим числом сегментов из рассмотренных выше вариантов;
- сегментация с использованием k-means++ с классификацией медианы с тем же числом сегментов.

Для медианной предобработки использовались размеры окна от 3×3 до 9×9 (в таблице отражены значения от 3×3 до 5×5); для постобработки по результатам предварительных испытаний были выбраны окно 3×3 и $L = 5$ (из 8 возможных).

Таблица 5. Влияние пред- и постобработки на точность классификации (локализованный способ формирования обучающей выборки).

Метод классификации	Размер окна при предобработке	Постобработка	Пиксели			Процент площади			
			15	50	100	1	5	10	25
Поэлементная классификация	1×1		0.494	0.571	0.618	0.498	0.570	0.612	0.737
	3×3		0.501	0.570	0.649	0.516	0.582	0.637	0.756
	5×5		0.469	0.574	0.656	0.463	0.578	0.655	0.774
	1×1	+	0.517	0.600	0.642	0.520	0.607	0.640	0.776
	3×3	+	0.510	0.582	0.664	0.526	0.591	0.647	0.781
	5×5	+	0.474	0.586	0.665	0.468	0.583	0.662	0.784
Сегментация k-means++ с голосованием большинства	1×1		0.514	0.609	0.637	0.513	0.602	0.634	0.782
	3×3		0.512	0.581	0.650	0.530	0.599	0.639	0.778
	5×5		0.486	0.588	0.658	0.478	0.588	0.655	0.805
	1×1	+	0.517	0.617	0.644	0.516	0.611	0.637	0.787
	3×3	+	0.514	0.584	0.654	0.533	0.602	0.642	0.784
	5×5	+	0.488	0.591	0.659	0.478	0.589	0.657	0.806
Сегментация k-means++ с классификацией медиан	1×1		0.495	0.588	0.618	0.497	0.577	0.618	0.769
	3×3		0.514	0.567	0.648	0.521	0.590	0.640	0.755
	5×5		0.484	0.582	0.676	0.473	0.576	0.656	0.807
	1×1	+	0.503	0.603	0.628	0.506	0.597	0.632	0.788
	3×3	+	0.518	0.573	0.655	0.526	0.594	0.645	0.764
	5×5	+	0.488	0.584	0.679	0.474	0.578	0.659	0.809
Наибольший прирост в процентах относительно поэлементной классификации			4.758	8.105	11.00	7.020	7.186	8.212	9.751

По результатам эксперимента можно сделать следующие выводы. Постобработка существенно улучшает качество классификации, поскольку все лучшие результаты были получены на данных, подвергшихся постобработке. Предобработка при использовании локализованной выборки не всегда повышает точность классификации. Однако при рандомизированной выборке её положительное влияние на точность классификации очевидно. Данные по наибольшим приростам в процентах относительно поэлементной классификации для каждой длины выборки говорят о том, что рассмотренные процедуры позволяют обеспечить прирост от 1.34% до 11%. Из двух методов агрегации результатов сегментации и классификации чаще даёт лучший результат голосование большинства.

Таблица 6. Влияние пред- и постобработки на точность классификации (локализованный способ формирования обучающей выборки).

Метод классификации	Размер окна при предобработке	Постобработка	Пиксели			Процент площади			
			15	50	100	1	5	10	25
Поэлементная классификация	1×1		0.519	0.619	0.628	0.695	0.718	0.720	0.718
	3×3		0.522	0.626	0.634	0.700	0.722	0.714	0.702
	5×5		0.520	0.606	0.634	0.695	0.716	0.703	0.683
	1×1	+	0.521	0.630	0.633	0.703	0.725	0.727	0.726
	3×3	+	0.526	0.628	0.636	0.699	0.722	0.714	0.706
	5×5	+	0.520	0.606	0.633	0.693	0.715	0.702	0.684
Сегментация k-means++ с голосованием большинства	1×1		0.519	0.650	0.660	0.715	0.717	0.739	0.739
	3×3		0.503	0.653	0.629	0.701	0.718	0.730	0.656
	5×5		0.482	0.613	0.675	0.702	0.725	0.741	0.645
	1×1	+	0.519	0.656	0.666	0.716	0.718	0.741	0.744
	3×3	+	0.502	0.654	0.630	0.699	0.718	0.730	0.657
	5×5	+	0.481	0.614	0.674	0.701	0.724	0.741	0.644
Сегментация k-means++ с классификацией медиан	1×1		0.519	0.638	0.649	0.707	0.710	0.733	0.737
	3×3		0.502	0.656	0.631	0.702	0.717	0.730	0.658
	5×5		0.482	0.613	0.666	0.703	0.729	0.743	0.647
	1×1	+	0.520	0.648	0.655	0.711	0.713	0.737	0.743
	3×3	+	0.500	0.659	0.632	0.700	0.717	0.730	0.657
	5×5	+	0.482	0.614	0.665	0.701	0.728	0.742	0.646
Наибольший прирост в процентах относительно поэлементной классификации			4.758	8.105	11.00	7.020	7.186	8.212	9.751

6. Выводы по итогам проведённых исследований

Таким образом, по результатам проведённых экспериментов можно сделать следующие выводы:

1. При отборе эталонных участков территории, используемых в качестве обучающей выборки, важно, чтобы как можно больше участков одного класса были территориально удалены друг от друга, поскольку это значительно повышает точность последующей классификации. Если имеющиеся данные не прошли предварительную процедуру атмосферной коррекции, это не является значительным препятствием к проведению тематической классификации (главное – чтобы эксперт мог отметить достаточное количество эталонных участков).

2. В качестве предварительной обработки данных целесообразно применять в сочетании методы NARC и PCA.

3. В качестве модели базового классификатора допустимо использовать SVM-RBF, при этом при обучении желательно перебрать несколько наборов параметров регуляризации и ширины окна.

4. Помимо спектральной, для некоторых данных целесообразно также применять пространственную предобработку данных – медианную фильтрацию с окнами от 3×3 до 5×5. Однако наибольший положительный эффект в такой процедуре достигается при

использовании “рандомизированной” выборки. Если выборка локализована, то лучше использовать небольшой размер окна – 3×3 , или вовсе пропустить этот этап.

5. Для учёта спектральных и пространственных связей между точками изображения следует применять какой-либо алгоритм сегментации, обеспечивающий большое (несколько тысяч) число сегментов. Например, в качестве такого алгоритма можно применять кластеризацию *k-means++* с последующей разметкой связанных областей. Для агрегации результатов сегментации и классификации голосование большинства чаще обеспечивает лучший результат.

6. Полученные результаты классификации целесообразно подвергнуть также нелинейной процедуре постобработки. Рабочий вариант её параметров – окно 3×3 и $L = 5$.

7. Дополнительно рекомендуется провести переклассификацию областей малой площади при наличии соответствующей априорной информации.

8. Как показали исследования, использование выбранной технологии может обеспечить прирост в точности классификации до 11% на выбранном изображении.

7. Благодарности

Работа выполнена при поддержке РФФИ (гранты 16-29-09494, 16-41-630676), а также в рамках госзадания ФАНО России по теме №0026-2018-0106.

8. Литература

- [1] Зимичев, Е.А. Пространственная классификация гиперспектральных изображений с использованием метода кластеризации *k-means++* / Е.А. Зимичев, Н.Л. Казанский, П.Г. Серафимович // Компьютерная оптика. – 2014. – Т. 38, № 2. – С. 281-286.
- [2] Борзов, С.М. Исследование эффективности спектрально-пространственной классификации данных гиперспектральных наблюдений / С.М. Борзов, О.И. Потатуркин // Автометрия. – 2017. – Т. 53, № 1. – С. 32-42.
- [3] Xu, Y. Atmospheric correction of hyperspectral data using MODTRAN model / Y. Xu, R. Wang, S. Liu, S. Yang, B. Yan // Proceedings of SPIE. – 2008. – Vol. 7123. – 712306 (7 pp.). DOI: 10.1117/12.815552.
- [4] Белов, А.М. Атмосферная коррекция гиперспектральных изображений с помощью приближённого решения уравнения переноса MODTRAN / А.М. Белов, В.В. Мясников // Компьютерная оптика. – 2014. – Т. 38, № 3. – С. 489-493.
- [5] Денисова, А.Ю. Атмосферная коррекция гиперспектральных изображений с использованием верифицированных данных малого объема / А.Ю. Денисова, В.В. Мясников // Компьютерная оптика. – 2016. – Т. 40, № 4. – С. 526-534.
- [6] Кузнецов, А.В. Сравнение алгоритмов управляемой поэлементной классификации гиперспектральных изображений / А.В. Кузнецов, В.В. Мясников // Компьютерная оптика. – 2014. – Т. 38, № 3. – С. 494-502.
- [7] Green, A.A. A transformation for ordering multispectral data in terms of image quality with implications for noise removal / A.A. Green et al. // IEEE Transactions on Geoscience and Remote Sensing. – 1988. – Vol. 26(1). – P. 65-74.
- [8] Lee, J.B. Enhancement of high spectral resolution remote-sensing data by a noise-adjusted principal components transform / J. B. Lee, A. S. Woodyatt, M. Berman // IEEE Transactions on Geoscience and Remote Sensing. – 1990. – Vol. 28(3). – P. 295-304.
- [9] Comaniciu, D. Mean shift: A robust approach towards feature space analysis / D. Comaniciu, P. Meer // IEEE Trans. Pattern Analysis and Machine Intelligence. – 2002. – Vol. 24. – P. 603-619.
- [10] Arthur, D. *K-means++*: The advantages of careful seeding / D. Arthur, S. Vassilvitskii // Proceedings of the eighteenth annual ACM-SIAM symposium on discrete algorithms. – Society for Industrial and Applied Mathematics, 2007. – P. 1027-1035.

Hyperspectral satellite image classification using small training data from its own territory

V.A. Fedoseev^{1,2}

¹Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

²Samara National Research University, Moskovskoe Shosse 34, Samara, Russia, 443086

Abstract. The paper is aimed to select an appropriate technique and some specific algorithms to perform thematic classification of hyperspectral satellite images based on small training sets of data selected manually from localized image parts. This technique is necessary in the case of the lack of sensing condition data and territory data and quite frequent in practice. The selected technology includes the stages of pixel-wise and spatial preprocessing of the analyzed image, its classification based on spatial and spectral factors, as well as spatial postprocessing of the classification results. Experimental studies have shown a significant decrease in the classification quality under the conditions considered in the paper. As a result of the experiments, the highest results were achieved by the algorithm based on combining pixel-wise classification results and segmentation results obtained using k-means++ and connected components filling, supplemented by nonlinear pre- and post-processing methods. The findings are supported by the results of comparative studies of different methods at each stage of the classification.

Keywords: hyperspectral imagery, spatial classification, comparative study.