# Разработка метода спектрально-пространственной классификации гиперспектральных изображений, основанного на локальном мультифрактальном анализе и методе опорных векторов

#### Дм. В. Учаев

Московский государственный университет геодезии и картографии, Москва, 105064, Россия E-mail: d-uchaev@yandex.ru

Повышение качества классификации является сегодня одной из ключевых проблем теории и практики обработки гиперспектральных изображений. Одним из путей решения этой задачи становится привлечение в процесс классификации пространственной (контекстной) информации. В статье предлагается новый метод спектрально-пространственной классификации гиперспектральных изображений, в котором в качестве пространственных признаков используются мультифрактальные характеристики и значения ёмкости Шоке, рассчитываемые с помощью локального мультифрактального анализа. В работе выделяются три группы мультифрактальных характеристик, которые могут использоваться в качестве классификационных признаков: глобальные, рассчитываемые для относительно крупных окрестностей пикселей; величины, вычисляемые на основе значений глобальных мультифрактальных характеристик, и локальные. Объединение пространственных признаков со спектральной информацией предлагается выполнять посредством классификатора, основанного на методе опорных векторов. Апробация метода проводится на двух тестовых гиперспектральных изображениях Pavia University и Salinas, имеющих разное пространственное разрешение. Результаты апробации показывают, что разработанный метод превосходит аналогичные по таким показателям качества классификации как общая точность и показатель каппа.

Ключевые слова: гиперспектральное изображение, машина опорных векторов, гёльдеровская экспонента, мультифрактал

Одобрена к печати: 08.11.2018 DOI: 10.21046/2070-7401-2019-16-1-46-57

#### Введение

В последние годы было предложено большое количество методов попиксельной классификации гиперспектральных изображений (ГИ) (Eismann, 2012). Данные методы присваивают каждый пиксель изображения одному из классов на основе только его спектральных свойств, не принимая в расчёт пространственно смежные пиксели. Однако в реальном изображении соседние пиксели связаны и коррелируют друг с другом, что обусловлено следующими факторами: а) датчики систем построения изображений, установленные на ресурсных спутниках дистанционного зондирования, получают существенное количество энергии от смежных пикселей; б) однородные структуры на сцене изображения по размерам, как правило, существенно превосходят пиксели. Например, если некоторый пиксель на изображении сельскохозяйственных угодий отображает площадку, занятую зерновой культурой, смежные с ним пиксели с высокой долей вероятности также соответствуют участку, занятому зерновыми культурами. Эта пространственная (контекстная) информация может помочь точной интерпретации сцены. Поэтому для улучшения результатов классификации имеет смысл использовать методы спектрально-пространственной классификации (СПК), которые присваивают каждый пиксель изображения одному классу как на основе его спектральных значений (спектральной информации), так и на основе данных, извлечённых из его пространственного окружения (пространственной информации).

К настоящему времени предложено множество подходов к СПК ГИ, однако разработка таких методов по-прежнему остаётся актуальной. Причиной этого является отсутствие в сообществе специалистов в области классификации ГИ единого взгляда на то, что собой представляет «пространственная зависимость пикселей» и как целесообразно её описывать при решении задачи классификации ГИ, чтобы получаемый результат обладал наивысшим качеством. В данной работе предлагается взглянуть на эти вопросы с позиции теории мультифракталов, в которой ключевым свойством текстур изображений считается масштабное самоподобие, а пространственная зависимость пикселей рассматривается как результат пространственная зображения, измеряемого сингулярного поведения функции интенсивностей изображения, измеряемого посредством гёльдеровских экспонент (Levy Vehel et al., 1992). Используя данный подход, автор настоящей работы предлагает новый метод СПК ГИ и на примере двух тестовых наборов данных демонстрирует его возможности в сравнении с аналогичными методами.

Цель данной работы — представить результаты разработки метода СПК ГИ, основанного на локальном мультифрактальном анализе (ЛМФА) и методе опорных векторов (МОВ).

#### ЛМФА космических изображений высокого разрешения

В настоящее время теория мультифракталов широко используется для локального пространственного анализа космических изображений высокого разрешения (Малинников и др., 2010; Zhang et al., 2008). При ЛМФА каждому каналу изображения сопоставляются матрицы значений одной или нескольких мультифрактальных характеристик:

- глобальных мультифрактальных характеристик: размерностей Реньи D<sub>q</sub> для некоторых выделенных значений q (например, D<sub>0</sub>, D<sub>1</sub>, D<sub>2</sub>), индексов сингулярности α(q) для некоторых выделенных значений q (например, α<sub>0</sub>, α<sub>min</sub> = α(q<sub>max</sub>), α<sub>max</sub> = α(q<sub>min</sub>)), фрактальных размерностей f<sub>L</sub>(α) для некоторых выделенных значений α (например, f<sub>L</sub>(α<sub>min</sub>), f<sub>L</sub>(α<sub>min</sub>)) и т.д. (Малинников и др., 2010);
- величин, рассчитываемых на основе значений глобальных мультифрактальных характеристик (Малинников и др., 2010, 2014):

$$\Delta_L \alpha = \alpha_0 - \alpha_{\min}, \quad \Delta_R \alpha = \alpha_{\max} - \alpha_0, \quad \Delta \alpha = \alpha_{\max} - \alpha_{\min}, \quad S_L = \int_{\alpha_{\min}}^{\alpha_0} f_L(\alpha) \, d\alpha,$$
$$S_R = \int_{\alpha_0}^{\alpha_{\max}} f_L(\alpha) \, d\alpha, \quad S_f = S_R + S_L, \quad r = \frac{\Delta_L \alpha}{\Delta_R \alpha}, \quad R = \frac{\Delta_L \alpha - \Delta_R \alpha}{\Delta_L \alpha + \Delta_R \alpha}, \quad \Delta_q D = D_1 - D_q \quad (q \gg 1);$$

• локальных мультифрактальных характеристик (Малинников, Учаев, 2008; Малинников и др., 2010):

$$\alpha(x,y) = \lim_{\varepsilon \to 0} \frac{\ln \left| \mu(B_{\varepsilon}(x,y) \right|}{\ln \varepsilon}, \quad f_{L} \left[ \alpha(x,y) \right] = \inf_{q \in R} \left\{ \alpha(x,y)q - \tau(q) \right\},$$

где  $\mu[B_{\epsilon}(x, y)]$  — ёмкости Шоке, рассчитываемые для окрестности  $B_{\epsilon}(x, y)$  пикселя с координатами (*x*, *y*) ( $\epsilon$  — линейный размер окрестности).

В настоящей работе перечисленные выше мультифрактальные характеристики предлагается использовать в качестве классификационных признаков, а их набор именовать, соответственно, профилем мультифрактальных признаков. Отдельно стоит обратить внимание на ёмкости Шоке. Данные характеристики сами по себе не описывают фрактальные свойства своего носителя (изображения) и поэтому, как правило, не рассматриваются в качестве значимого результата ЛМФА. Однако в представленной работе целью ЛМФА является извлечение из исходного изображения классификационных признаков, а для этой цели ёмкости Шоке обладают полезным свойством: в отличие от мультифрактальных характеристик они масштабно не инвариантны (т.е. не инварианты по отношению к преобразованию подобия изображения). Учитывая это, матрицы значений ёмкости Шоке можно рассматривать в качестве классификационных признаков, дополняющих по своим свойствам профиль мультифрактальных признаков. Формируемый таким образом профиль предлагается именовать расширенным профилем мультифрактальных признаков (Extended Holder Profile (EHP)).

## Метод СПК ГИ, основанный на ЛМФА и МОВ

Сущность представленного метода состоит в использовании в качестве пространственных признаков наборов характеристик, рассчитываемых с помощью процедуры ЛМФА. Спектральную и пространственную информацию предлагается комбинировать в классификаторе попиксельной классификации ядерного типа. При таком подходе ключевой задачей является выбор классификатора, способного эффективно классифицировать вектора с большим числом признаков, а учитывая специфику гиперспектральных изображений, ещё и при малом объёме обучающих данных. Одним из наиболее предпочтительных кандидатов на эту роль является классификатор, основанный на методе опорных векторов (КМОВ) (Учаев и др., 2017). В настоящее время КМОВ широко используется в различных методах СПК ГИ (см., например, работу (Ye et al., 2017)). Большая популярность данного классификатора обусловлена его достоинствами: простотой устройства, относительно низкой вычислительной сложностью, наличием фазы обучения, связанной с оптимизацией выпуклой функции стоимости, и высоким уровнем масштабируемости (Vapnik, 1998). Являясь классификатором ядерного типа, КМОВ позволяет объединять спектральную и пространственную информацию различными способами. Одним из них является объединение множеств спектральных и пространственных признаков для каждого вектора признаков на этапе подготовки исходных для КМОВ данных. Этот способ предлагается использовать и в разработанном методе. На рис. 1 изображена технологическая схема нового метода.



*Рис. 1.* Схема предлагаемого метода СПК ГИ (пунктиром указаны необязательные этапы)

Как видно на *рис.* 1, на первом этапе классификации производится добывание информативных спектральных признаков (Feature Spectral Mining). Для этих целей могут быть использованы любые алгоритмы отбора признаков (Feature Selection) (Чабан и др., 2014) или извлечения признаков (Feature Extraction) (Jia et al., 2013), например анализ главных компонент (ГК) (Principal Component Analysis (PCA)), метод извлечения признаков на основе разделяющей поверхности (Decision Boundary Feature Extraction (DBFE)) (Lee, Landgrebe, 1993) или непараметрический взвешенный метод извлечения признаков (Nonparametric Weighted Feature Extraction (NWFE)) (Kuo, Landgrebe, 2004)). Далее создаётся единый профиль мультифрактальных признаков на базе значений мультифрактальных характеристик, рассчитываемых для каждого изображения информативного спектрального признака. Выбор мультифрактальных характеристик, используемых в качестве классификационных признаков, должен учитывать как особенности их расчёта (например, аппроксимирующий характер лежандровских мультифрактальных спектров и границы самоподобия функции интенсивности в пределах области расчёта признаков), так и зависимость от качества изображения, по которому они рассчитываются (его контраста, наличия шумов и т.д.) (Uchaev et al., 2015, 2017). В целом проблема выбора мультифрактальных характеристик в качестве классификационных признаков на сегодняшний день является исследовательской задачей, объём и многоаспектность которой заслуживает отдельной публикации, и, как следствие, в данной работе не рассматривается.

На следующем этапе предлагаемого метода полученный профиль мультифрактальных признаков объединяется с набором информативных спектральных признаков. К образованному таким образом набору также при необходимости могут быть применены методы добывания признаков, сокращающие их количество и, следовательно, уменьшающие время работы используемого впоследствии КМОВ. Заключительным этапом является классификация итогового набора признаков с помощью КМОВ и оценка качества результатов классификации.

#### Описание тестовых наборов данных

Апробация разработанного метода проводилась на двух тестовых наборах данных (*puc. 2, 3*, см. с. 50), размещённых в интернете в свободном доступе по адресу http://www.ehu.eus/ ccwintco/index.php?title=Hyperspectral\_Remote\_Sensing\_Scenes. Размеры обучающей и тестовой выборок пикселей, созданных на основе тестовых наборов данных, представлены в *maбл. 1* и 2.



*Рис. 2.* Тестовый набор данных Pavia University: *а* — цветное RGB-композитное изображение, составленное из 46 (R), 27 (G) и 10 (B) каналов ГИ; *б* — эталонное разбиение на классы



*Рис. 3.* Тестовый набор данных Salinas: a — цветное RGB-композитное изображение, составленное из 35 (R), 19 (G) и 9 (B) каналов ГИ;  $\delta$  — эталонное разбиение на классы

Класс		Выборка		
Nº	Название	Обучающая	Тестовая	
1	Асфальт	548	6631	
2	Луга	540	18 649	
3	Гравий	392	2099	
4	Деревья	524	3064	
5	Металлические листы	265	1345	
6	Обнажённая почва	532	5029	
7	Битум	375	1330	
8	Кирпичи	514	3682	
9	Тени	231	947	
	Итого	3921	42 776	

Таблица 1. Размеры обучающих и тестовых выборок для набора данных Pavia University

*Таблица 2*. Размеры обучающих и тестовых выборок для набора данных Salinas

	Класс	Выборка		
N⁰	Название	Обучающая	Тестовая	
1	Брокколи с малым количеством низких зелёных сорняков	241	1768	
2	Брокколи с большим количеством высоких зелёных сорняков	423	3303	
3	Пары	255	1721	
4	Пары (глыбистая вспашка)	187	1207	
5	Пары (гладкая вспашка)	370	2308	
6	Жнивьё	512	3447	
7	Сельдерей	456	3123	
8	Виноград (необработанный)	1399	9872	
9	Почвы, разрабатываемые под виноградник	761	5442	
10	Стареющая пшеница и зелёные сорняки	408	2870	
11	Салат ромэн (возраст 4 нед, <5 % зелёного покрова)	129	939	
12	Салат ромэн (возраст 5 нед, 10 % зелёного покрова)	224	1703	
13	Салат ромэн (возраст 6 нед, 20 % зелёного покрова)	113	803	
14	Салат ромэн (возраст 7 нед, 40-50 % зелёного покрова)	142	928	
15	Виноградник (необработанный)	921	6347	
16	Виноградник (вертикальные шпалеры)	225	1582	
	Итого	6766	47 363	

Набор данных Pavia University содержит ГИ территории Павийского университета (Италия), полученное с помощью авиационного гиперспектрометра ROSIS 8 июля 2002 г., и соответствующее ему подтверждённое наземными исследованиями эталонное разбиение на классы. Гиперспектральное изображение имеет размеры 340×610 пикселей и 103 спектральных канала. Из описания к набору данных следует, что исходное ГИ имело 115 каналов, содержащих зарегистрированное излучение в диапазоне длин волн 0,43–0,86 мкм, из которых 12 каналов были удалены из-за шума. Среднее пространственное разрешение ГИ Раvia University составляет 1,3 м. На изображении представлены девять классов, характерные для городского ландшафта (см. *рис. 2*).

Набор данных Salinas включает в себя ГИ территории южнее города Гринфилд в долине Салинас (Калифорния, США), полученное с помощью авиационного гиперспектрометра AVIRIS 9 октября 1998 г., и соответствующее ему подтверждённое наземными исследованиями эталонное разбиение на классы. Гиперспектральное изображение имеет размеры 217×512 пикселей и 204 спектральных канала. Из описания к набору данных следует, что исходное ГИ имело 224 канала, содержащих зарегистрированное излучение в диапазоне длин волн 0,4–2,5 мкм, из которых 20 сильно зашумленных каналов (108–112, 154–167 и 224) были удалены. Среднее пространственное разрешение ГИ Salinas составляет 3,7 м. На изображении представлены участки поверхности Земли с восемью типами сельскохозяйственных культур, а также три типа участков обнажённых почв и три типа участков, занятых виноградниками (см. *рис. 3*).

# Результаты экспериментальной апробации разработанного метода

В данной работе извлечение признаков проводилось с помощью метода РСА. Результатом применения метода стали пять изображений ГК для каждого тестового изображения, содержащие приблизительно 99,5 и 99,9 % всей дисперсии ГИ Pavia University и Salinas coorветственно. Далее для каждого полученного изображения ГК был построен расширенный профиль мультифрактальных признаков. Данный профиль составлялся из матриц значений гёльдеровских экспонент  $\alpha(x, y)$  и соответствующих им значений ёмкости Шоке, рассчитываемых методом скользящего окна с размерами окон 3, 7, 15, 31 и 63 пикселей (матрицы значений ёмкости Шоке, определённые для скользящих окон размером в один пиксель, также использовались для расчёта гёльдеровских экспонент, однако из-за их совпадения с ГК в профиль не включались). При этом значения ёмкости Шоке рассчитывались как сумма яркостей пикселей, попадающих в границы скользящих окон. Построенный таким образом профиль мультифрактальных признаков впоследствии объединялся с изображениями ГК, формируя тем самым итоговый набор классификационных признаков. Классификация итогового набора признаков осуществлялась посредством КМОВ, реализованного в модуле imageSVM в программе EnMAP-Box (http://www.enmap.org/enmapbox.html). В качестве функции ядра была использована радиальная базисная функция. Данный выбор был сделан исходя из опыта применения различных функций ядер для классификации ГИ (см., например, (Melgani, Bruzzone, 2004)). В этом классификаторе имеется два параметра: ширина ядра у и параметр регуляризации С (Учаев и др., 2017). Оптимальные значения данных параметров обнаруживались методом перебора на множестве значений  $\{10^{-2}, 10^{-1}, 10^{0}, 10^{1}, 10^{2}, 10^{3}\}$  параметров у и C с использованием трёхкратной перекрёстной проверки (3-fold cross-validation). Полученные результаты классификации сравнивались с результатами классификации данных изображений аналогичными методами СПК, имеющимися в открытой печати. Для ГИ Pavia University сравниваемыми методами являлись:

 Классификация МОВ набора векторов признаков, составленного из 37 признаков, извлечённых методом DBFE из оригинального ГИ (27 признаков) и расширенного морфологического профиля (Extended Morphological Profile (EMP)) (10 признаков), построенного на базе первых трёх ГК (4 открытия/закрытия для каждой ГК) исходного ГИ (DBFE–EMP–SVM) (Fauvel, 2007).

- 2. Классификация МОВ набора векторов признаков, составленного из признаков, извлечённых методом NWFE из оригинального ГИ (7 признаков) и EMP, построенного тем же способом, что и в первом методе (NWFE–EMP–SVM) (6 признаков) (Fauvel, 2007).
- 3. Использование метода Area Filtering (AF) (Soille, 2005), применённого к первой ГК исходного ГИ, затем вычисление для каждого пикселя каждого канала исходного изображения векторных медиан в соответствующей адаптивной окрестности, определённой в пределах связных зон размером в 30 пикселей, и, наконец, выполнение классификации КМОВ с взвешенным ядром суммирования (Camps-Valls et al., 2006) для объединённой спектральной (исходного изображения (HSI)) и пространственной (значений векторных медиан) информации (HSI–AF–SVM) (Fauvel, 2007; Fauvel et al., 2012).
- 4. Классификация МОВ набора векторов признаков, составленного из ЕМР, построенного на базе первых трёх ГК (4 открытия/закрытия для каждой ГК) исходного ГИ, и исходного ГИ (HSI–EMP–SVM) (Fauvel, 2007).
- 5. Классификация, основанная на сегментации методом водоразделов с использованием робастного цветного морфологического градиента (Robust Color Morphological Gradient (RCMG)) (RCMG–SVM) (Tarabalka et al., 2010).



*Рис. 4.* Классификационные карты, полученные различными методами СПК ГИ Pavia University: a — DBFE–EMP–SVM;  $\delta$  — NWFE–EMP–SVM;  $\epsilon$  — HSI–AF–SVM;  $\epsilon$  — RCMG–SVM;  $\partial$  — PCA–EHP–SVM



*Puc. 5.* Классификационные карты, полученные различными методами СПК ГИ Salinas: *a* — KMeansS-VM 16; *б* — KMeansSVM 20; *в* — HMRFSVM–NE 16; *г* — HMRFSVM–NE 20; *д* — HMRFSVM–E 16; *e* — HMRFSVM–E 20; *ж* — PCA–EHP–SVM

В свою очередь, результаты классификации ГИ Salinas сравнивались с результатами классификации данного ГИ методами, основанными на применении скрытых марковских случайных полей (Hidden Markov Random Field (HMRF)), предложенными в работе (Ghamisi et al., 2014). В *табл. 3, 4* приведены оценки качества классификации всеми перечисленными выше методами, а на *рис. 4, 5* (см. с. 52) — имеющиеся в распоряжении автора классификационные карты (предлагаемый метод обозначен PCA–EHP–SVM). Для оценки качества классификации использовались такие характеристики матрицы ошибок, как общая точность (Overall Accuracy (OA)), поклассовая точность производителя (Producer's Accuracy (PA)), средняя точность (Average Accuracy (AA)) и показатель к.

Показатель	DBFE-EMP-SVM	NWFE-EMP-SVM	HSI-AF-SVM	HSI-EMP-SVM	RCMG-SVM*	PCA-EHP-SVM
PA 1	90,92	86,80	84,36	95,32	93,64	74,30
PA 2	85,91	86,96	78,52	73,46	75,09	99,25
PA 3	57,88	63,27	84,80	65,89	66,12	65,56
PA 4	99,22	98,53	96,87	99,18	98,56	95,59
PA 5	99,48	99,55	99,88	99,48	99,91	99,78
PA 6	85,33	82,62	95,61	84,15	97,35	94,35
PA 7	95,19	96,62	95,56	97,22	96,23	93,16
PA 8	95,84	95,38	95,44	96,12	97,92	94,79
PA 9	95,14	90,60	97,78	93,66	96,98	90,92
OA	87,97	87,59	86,11	83,53	85,42	92,15
AA	89,43	88,93	91,98	89,39	91,31	89,74
к	84,40	83,89	82,35	79,13	81,30	89,59

*Таблица 3.* Результаты оценки точности СПК ГИ Pavia University с помощью разработанного метода и его аналогов (полужирным шрифтом выделены наилучшие результаты)

\* Результаты получены с использованием такой же обучающей выборки и меньшей тестовой выборки.

		· · · · · · · · · · · · · · · · · · ·	·		γ		
Показатель	Kmeans SVM 16	Kmeans SVM 20	HMRFSVM- NE 16	HMRFSVM- NE 20	HMRFSVM- E 16	HMRFSVM- E 20	PCA– EHP–SVM
<b>PA</b> 1	100,00	100,00	100,00	100,00	100,00	100,00	100,00
PA 2	100,00	100,00	100,00	100,00	100,00	100,00	100,00
PA 3	99,70	99,50	99,70	99,70	99,70	99,70	100,00
PA 4	99,80	99,80	99,80	99,80	99,80	99,80	99,42
PA 5	98,50	98,80	85,30	98,90	86,80	99,10	99,78
PA 6	99,70	99,90	98,50	99,60	98,60	99,80	99,97
PA 7	99,40	99,40	99,40	99,40	99,40	99,50	99,97
PA 8	95,80	94,30	95,60	95,00	96,20	95,10	99,96
PA 9	99,90	99,90	99,90	99,70	99,90	99,60	100,00
PA 10	96,70	95,70	90,80	90,80	90,60	91,90	99,83
PA 11	99,00	98,90	99,00	99,00	99,00	99,00	100,00
PA 12	99,80	99,80	100,00	99,80	100,00	100,00	100,00
PA 13	98,90	98,80	98,60	98,80	98,80	99,00	100,00
PA 14	95,40	95,80	97,20	96,00	97,10	96,30	98,92
PA 15	43,20	90,00	92,90	92,60	92,80	92,80	99,97
PA 16	98,90	98,90	99,30	99,00	99,10	99,20	100,00
OA	91,01	96,93	96,57	97,10	96,76	97,24	99,93
AA	95,29	98,09	97,25	98,00	97,36	98,18	99,91
к	89,93	96,58	96,18	96,77	96,39	96,92	99,92

Таблица 4. Результаты оценки точности СПК ГИ Salinas с помощью разработанного метода и его аналогов (полужирным шрифтом выделены наилучшие результаты)

Из представленных классификационных карт наглядно видно, что разработанный метод превосходит аналогичные по качеству классификации областей ГИ, занятых низкорослой растительностью, и уступает сравниваемым методам в качестве классификации областей ГИ Pavia University, отображающих асфальтовые покрытия. Остальные классы объектов определяются на обоих ГИ приблизительно с одинаковой точностью. Это подтверждается и количественными оценками результатов классификации: высокие значения РА наблюдаются для подавляющего большинства классов ГИ Salinas и для класса «Луга» ГИ Pavia University. Данный вывод объясняет также высокие значения комплексных оценок качества ОА и к, полученные для классификационных карт тестовых ГИ, для которых успешно классифицируемые объекты местности были доминирующими в смысле занимаемой ими площади. Полученные результаты позволяют заключить, что предлагаемый в работе метод имеет значительный потенциал при классификации ГИ, в особенности когда целевыми являются объекты местности, представимые на ГИ относительно крупными однородными областями (например, ГИ сельскохозяйственных угодий).

#### Заключение

В результате проведённой работы были получены следующие научные и практические результаты:

- 1. Разработан метод СПК ГИ, базирующийся на локальном мультифрактальном анализе и МОВ.
- 2. Проведена экспериментальная апробация метода на двух тестовых наборах данных: Pavia University и Salinas.
- Проведено сопоставление предложенного метода с альтернативными методами СПК ГИ. В результате установлено, что разработанный метод классификации превосходит рассматриваемые аналоги по таким показателям качества классификации, как общая точность классификации и показатель к.

В дальнейшем автор планирует провести экспериментальную апробацию разработанного метода на большем наборе данных, полученных с использованием разных гиперспектральных датчиков, а также рассмотреть возможность повышения точности классификации ГИ за счёт использования других мультифрактальных признаков.

Работа выполнена по инициативному научному проекту 5.6470.2017/8.9 в рамках базовой части государственного задания Минобрнауки РФ.

# Литература

- 1. *Малинников В.А., Учаев Д.В.* Применение методики мультифрактальной сегментации изображений для выделения контуров на аэрокосмических снимках // Известия вузов. Геодезия и аэрофотосъемка. 2008. № 6. С. 37–41.
- 2. *Малинников В.А., Учаев Д.В., Учаев Дм.В.* Разработка метода обобщенного локально-глобального мультифрактального анализа изображений для исследования пространственной структуры сложных природно-антропогенных систем // Известия вузов. Геодезия и аэрофотосъемка. 2010. № 4. С. 64–68.
- 3. *Малинникова О. Н., Малинников В.А., Учаев Дм. В., Учаев Д. В.* Асимметрия мультифрактальных спектров, описывающих поверхностную структуру углей выбросоопасных и невыбросоопасных пластов // Материалы 24-й Международной научной шк. «Деформирование и разрушение материалов с дефектами и динамические явления в горных породах и выработках». Алушта. 22–28 сент. 2014. Симферополь: Таврический нац. ун-т, 2014. С. 125–130.
- 4. *Учаев Д. В., Учаев Дм. В., Есипов А. С., Филатова Е. Г.* Фрактальный подход к выбору коэффициента сжатия гиперспектральных изображений в методе 3D-SPIHT при условии последующей классификации восстанавливаемых изображений методом опорных векторов // Современные проблемы дистанционного зондирования Земли из космоса. 2017. Т. 14. № 4. С. 9–23.

- 5. *Чабан Л. Н., Малинников В. А., Учаев Д. В., Учаев Дм. В.* Методы отбора информативных каналов при тематической обработке гиперспектральных изображений // Известия вузов. Геодезия и аэрофотосъемка. 2014. № 4. С. 63–74.
- 6. Eismann M. T. Hyperspectral Remote Sensing. Bellingham, Washington: SPIE Press, 2012. 748 p.
- 7. *Fauvel M*. Spectral and spatial methods for the classification of urban remote sensing data: Doctoral Thesis. Grenoble, 2007. 189 p.
- 8. *Fauvel M.*, *Chanussot J.*, *Benediktsson J.A.* A spatial-spectral kernel-based approach for the classification of remote-sensing images // Pattern Recognition. 2012. V. 45. No. 1. P. 381–392.
- Ghamisi P., Benediktsson J.A., Ulfarsson M.O. Spectral-Spatial Classification of Hyperspectral Images Based on Hidden Markov Random Fields // IEEE Trans. Geoscience and Remote Sensing. 2014. V. 52. No. 5. P. 2565–2574.
- 10. *Jia X., Kuo B.-C., Crawford M. M.* Feature Mining for Hyperspectral Image Classification // Proc. IEEE. 2013. V. 101. No. 3. P. 676–697.
- 11. *Kuo B.-C., Landgrebe D.A.* Nonparametric weighted feature extraction for classification // IEEE Trans. Geoscience and Remote Sensing. 2004. V. 42. No. 5. P. 1096–1105.
- 12. *Lee C., Landgrebe D.A.* Feature extraction based on decision boundaries // IEEE Transactions on Pattern Analysis and Machine Intelligence. 1993. V. 15. No. 4. P. 388–400.
- 13. Levy Vehel J., Mignot P., Berroir J.-P. Multifractals, texture, and image analysis // Proc. CVPR'92. Champaign, 1992. P. 661–664.
- 14. *Melgani F., Bruzzone L.* Classification of Hyperspectral Remote Sensing Images With Support Vector Machines // IEEE Transactions on Geoscience and Remote Sensing. 2004. V. 42. No. 8. P. 1778–1790.
- Soille P. Beyond self-duality in morphological image analysis // Image and Vision Computing. 2005. V. 23. No. 2. P. 249–257.
- 16. *Tarabalka Y., Chanussot J., Benediktsson J.A.* Segmentation and classification of hyperspectral images using watershed transformation // Pattern Recognition. 2010. V. 43. No. 7. P. 2367–2379.
- 17. Uchaev Dm. V., Uchaev D. V., Malinnikov V.A. Image contrast enhancement using Chebyshev wavelet moments // Proc. SPIE. Barcelona, 2015. V. 9875. P. 987512.
- 18. Uchaev Dm. V., Uchaev D. V., Malinnikov V.A. Chebyshev-based technique for automated restoration of digital copies of faded photographic prints // J. Electronic Imaging. 2017. V. 26. No. 1. P. 011024.
- 19. Vapnik V. N. Statistical Learning Theory. 1st ed. N. Y.: Wiley-Interscience, 1998. 768 p.
- 20. Ye Z., Fowler J. E., Bai L. Spatial-spectral hyperspectral classification using local binary patterns and Markov random fields // J. Applied Remote Sensing. 2017. V. 11. No. 3. P. 035002.
- Zhang R., Tian J., Li Z., Sun X., Jiang X. Spatial scaling and information fractal dimension of surface parameters used in quantitative remote sensing // Intern. J. Remote Sensing. 2008. V. 29. No. 17. P. 5145–5159.

# Development of the method of spectral-spatial classification of hyperspectral images based on local multifractal analysis and the support vector machine

#### Dm. V. Uchaev

#### Moscow State University of Geodesy and Cartography, Moscow 105064, Russia E-mail: d-uchaev@yandex.ru

Today, improving the quality of classification of hyperspectral images is one of the main problems of the theory and practice of hyperspectral image processing. One way to solve this problem is to involve spatial (contextual) information in the process of classification. In the paper, a new method of spectral-spatial classification of hyperspectral images is proposed. In the method, the multifractal characteristics and values of the Choquet capacity, calculated using local multifractal analysis, are used as spatial features. The paper identifies three groups of multifractal characteristics that can be used as classification features: global multifractal characteristics calculated for relatively large pixel neighborhoods; characteristics derived from global multifractal characteristics and local multifractal characteristics. The combination of spatial features with spectral information in the proposed method is performed using the support vector machine classifier. Experiments are carried out with two hyper-spectral images of Pavia University and Salinas, having different spatial resolution. Experimental results demonstrate that the proposed method outperforms similar methods in terms of the overall accuracy and the kappa statistic.

Keywords: hyperspectral image, support vector machine, Holder exponent, multifractal

Accepted: 08.11.2018 DOI: 10.21046/2070-7401-2019-16-1-46-57

### References

- 1. Malinnikov V.A., Uchaev D.V., Primenenie metodiki mul'tifraktal'noi segmentatsii izobrazhenii dlya vydeleniya konturov na aerokosmicheskikh snimkakh (Application of the Technique of Multifractal Image Segmentation to Aerospace-Image Edge Detecting), *Izvestiya Vuzov. Geodeziya i aerofotos"emka*, 2008, No. 6, pp. 37–41.
- 2. Malinnikov V.A., Uchaev D.V., Uchaev Dm.V., Razrabotka metoda obobshchennogo lokal'no-global'nogo mul'tifraktal'nogo analiza izobrazhenii dlya issledovaniya prostranstvennoi struktury slozhnykh prirodno-antropogennykh sistem (A technique of generalized local-global multifractal analysis of images for research of spatial structure of complex natural-anthropogenic systems), *Izvestiya Vuzov. Geodeziya i aerofotos" emka*, 2010, No. 4, pp. 64–68.
- 3. Malinnikova O. N., Malinnikov V. A., Uchaev Dm. V., Uchaev D. V., Asimmetriya mul'tifraktal'nykh spektrov, opisyvayushchikh poverkhnostnuyu strukturu uglei vybrosoopasnykh i nevybrosoopasnykh plastov (Asymmetry of multifractal spectra describing the surface structure of coals of outburst-hazardous and outburst-nonhazardous beds), *Deformirovanie i razrushenie materialov s defektami i dinamicheskie yavleniya v gornykh porodakh i vyrabotkakh* (Deformation and Destruction of Materials with Defects and Dynamic Phenomena in Rocks and Working), Proc. 24<sup>th</sup> Intern. Scientific School, Alushta, Sept. 22–28, 2014, Simferopol: Tavricheskii natsional'nyi universitet, 2014, pp. 125–130.
- 4. Uchaev D. V., Uchaev Dm. V., Esipov A. S., Filatova E. G., Fraktal'nyi podkhod k vyboru koeffitsienta szhatiya giperspektral'nykh izobrazhenii v metode 3D-SPIHT pri uslovii posleduyushchei klassifikatsii vosstanavlivaemykh izobrazhenii metodom opornykh vektorov (Fractal approach to the choice of the compression ratio of hyperspectral images in the 3D–SPIHT method under the condition of subsequent classification of the decompressed images by the support vector machine), *Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2017, Vol. 14, No. 4, pp. 9–23.
- 5. Chaban L. N., Malinnikov V. A., Uchaev D. V., Uchaev Dm. V., Metody otbora informativnykh kanalov pri tematicheskoi obrabotke giperspektral'nykh izobrazhenii (Methods of selection of informative band for thematic processing of hyper-spectral images), *Izvestiya Vuzov. Geodeziya i aerofotos"emka*, 2014, No. 4, pp. 63–74.
- 6. Eismann M. T., Hyperspectral Remote Sensing, Bellingham, Washington: SPIE Press, 2012, 748 p.
- 7. Fauvel M., Spectral and spatial methods for the classification of urban remote sensing data: Doctoral Thesis, Grenoble, 2007, 189 p.
- 8. Fauvel M., Chanussot J., Benediktsson J.A., A spatial-spectral kernel-based approach for the classification of remote-sensing images, *Pattern Recognition*, 2012, Vol. 45, No. 1, pp. 381–392.
- 9. Ghamisi P., Benediktsson J.A., Ulfarsson M.O., Spectral-Spatial Classification of Hyperspectral Images Based on Hidden Markov Random Fields, *IEEE Transactions on Geoscience and Remote Sensing*, 2014, Vol. 52, No. 5, pp. 2565–2574.
- 10. Jia X., Kuo B.-C., Crawford M.M., Feature Mining for Hyperspectral Image Classification, *Proc. IEEE*, 2013, Vol. 101, No. 3, pp. 676–697.
- 11. Kuo B.-C., Landgrebe D.A., Nonparametric weighted feature extraction for classification, *IEEE Transactions on Geoscience and Remote Sensing*, 2004, Vol. 42, No. 5, pp. 1096–1105.
- 12. Lee C., Landgrebe D.A., Feature extraction based on decision boundaries, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1993, Vol. 15, No. 4, pp. 388–400.
- 13. Levy Vehel J., Mignot P., Berroir J.-P., Multifractals, texture, and image analysis, *Proc. CVPR'92*, Champaign, 1992, pp. 661–664.
- 14. Melgani F., Bruzzone L., Classification of Hyperspectral Remote Sensing Images With Support Vector Machines, *IEEE Transactions on Geoscience and Remote Sensing*, 2004, Vol. 42, No. 8, pp. 1778–1790.

- 15. Soille P., Beyond self-duality in morphological image analysis, *Image and Vision Computing*, 2005, Vol. 23, No. 2, pp. 249–257.
- 16. Tarabalka Y., Chanussot J., Benediktsson J.A., Segmentation and classification of hyperspectral images using watershed transformation, *Pattern Recognition*, 2010, Vol. 43, No. 7, pp. 2367–2379.
- 17. Uchaev Dm. V., Uchaev D. V., Malinnikov V.A., Image contrast enhancement using Chebyshev wavelet moments, *Proc. SPIE*, Barcelona, 2015, Vol. 9875, p. 987512.
- 18. Uchaev Dm. V., Uchaev D. V., Malinnikov V.A., Chebyshev-based technique for automated restoration of digital copies of faded photographic prints, *J. Electronic Imaging*, 2017, Vol. 26, No. 1, p. 011024.
- 19. Vapnik V. N., *Statistical Learning Theory*, 1<sup>st</sup> ed., New York: Wiley-Interscience, 1998, 768 p.
- 20. Ye Z., Fowler J. E., Bai L., Spatial-spectral hyperspectral classification using local binary patterns and Markov random fields, *J. Applied Remote Sensing*, 2017, Vol. 11, No. 3, p. 035002.
- Zhang R., Tian J., Li Z., Sun X., Jiang X., Spatial scaling and information fractal dimension of surface parameters used in quantitative remote sensing, *Intern. J. Remote Sensing*, 2008, Vol. 29, No. 17, pp. 5145–5159.