

# Классификация гиперспектральных изображений ДЗЗ с помощью высокоуровневых признаков на основе эмпирических мод

К.К. Пухкий<sup>1</sup>, В.Е. Турлапов<sup>1</sup>

<sup>1</sup> Нижегородский государственный университет им. Н. И. Лобачевского, проспект Гагарина, 23, Нижний Новгород, 603022, Россия

## Аннотация

Исследована роль эмпирических мод разложения EMD (empirical mode decomposition) в синтезе высокоуровневых признаков для классификации гиперспектральных изображений (HSI) ДЗЗ. Исследования выполнены на материале известного HSI Moffett Field. Использован алгоритм 1D-EMD адаптированный к потребностям анализа HSI. Установлено что: 1) эталон класса в форме только референсной сигнатуры (спектральной характеристики) не может быть признаком достаточным для классификации на полном изображении Moffett Field; 2) дополнение эталона класса объектов HSI, состоящего из его референсной сигнатуры, даже одной из первых эмпирических мод, либо увеличивает контрастность каждого из эталонов кардинальным образом, либо выявляет их принадлежность к одному классу; 3) эмпирические моды способны обеспечить необходимое уточнение эталона класса для всего разнообразия объектов HSI Moffett Field; 4) предложены правила формирования высокоуровневого спектрально специфицированного признака из эмпирических мод.

## Ключевые слова

Гиперспектральные изображения, классификация, разложение на эмпирические моды, матрица взаимных расстояний, спектрально специфицированный признак.

# Classification of Hyperspectral Remote Sensing Images Using High-level Features Based on Empirical Modes

К.К. Pukhkii<sup>1</sup>, V.E. Turlapov<sup>1</sup>

<sup>1</sup> The National Research State University of Nizhny Novgorod named after N.I. Lobachevsky, 23 Prospekt Gagarina, Nizhny Novgorod, 603022, Russia

## Abstract

The role of empirical mode decomposition (EMD) in the synthesis of high-level features for the classification of hyperspectral remote sensing images is studied. The studies were performed on the material of the well-known HSI "Moffett Field". A 1D-EMD algorithm adapted to the needs of HSI analysis was used. It has been established that: 1) class reference in the form of only a reference HSI-signature of a class sample cannot be a sufficient feature for classification on the full "Moffett Field" HSI; 2) the extension of an HSI-object class standard, consisting of a reference signature (spectral characteristic) of a class sample, even by one of the first empirical modes, either dramatically increases the contrast between the standards, or reveals the indistinguishability of the standards in the global coordinate system (belonging to the same class); 3) empirical modes are able to provide the necessary refinement of the class standard for a variety of HSI Moffett Field objects; 4) formation rules for a high-level spectral feature from empirical modes are proposed.

ГрафиКон 2023: 33-я Международная конференция по компьютерной графике и машинному зрению, 19-21 сентября 2023 г., Институт проблем управления им. В.А. Трапезникова Российской академии наук, г. Москва, Россия  
EMAIL: konstantin.pukhkiy@itlab.unn.ru (К.К. Пухкий); vadim.turlapov@itmm.unn.ru (В.Е. Турлапов)  
ORCID: 0000-0002-9144-5122 (К.К. Пухкий); 0000-0001-8484-0565 (В.Е. Турлапов)



© 2023 Copyright for this paper by its authors.  
Use permitted under Creative Commons License Attribution 4.0 International (CC BY 4.0).

**Keywords**

Hyperspectral images, classification, empirical mode decomposition, mutual distance matrix, spectrally specified feature.

**1. Введение**

Гиперспектральные изображения (HSI, hyperspectral images) являются результатом отражения света от, так называемой, подстилающей поверхности. Как правило, это поверхность Земли при ее дистанционном зондировании (ДЗЗ). Сотни каналов HSI имеют целью зафиксировать отражательные свойства объектов, которые могут изменяться на достаточно малых интервалах длин волн (порядка 3-10 нм), соответствующих ширине канала HSI. Именно благодаря характерному профилю спектральной характеристики отражения, HSI часто имеют возможность классифицировать объект по одному пикселю без исследования контекста. Эти возможности уже довольно успешно используются в земледелии для индикации состояния растений, почвы, влажности с помощью многочисленных вегетационных индексов. Замечены и высоко оценены они и как источник высокоуровневых признаков для классификации объектов с помощью искусственного интеллекта (ИИ). Так, статья Pan E., 2021 [1] предлагает вариант подхода «zero-shot learning» к классификации HSI объектов, использующий такие высокоуровневые признаки класса, что обучив модель на одном датасете, который содержит эти признаки, получаем возможность правильно классифицировать содержание других датасетов без дополнительного обучения. При этом обученная модель может переносить с собой также распознавание категорий/свойств объектов HSI, которые невидимы в этих других датасетах. В статье высокоуровневым признаком считалась спектральная характеристика (сигнатура) каждого пикселя. Тренировочный датасет для классов объектов формировался случайной выборкой малой доли пикселей из объектов каждого класса заданного HSI, тестовый - всеми оставшимися пикселями объектов. Статья оставляет читателю полную свободу для дальнейшего поиска других типов высокоуровневых признаков в конкретных практических задачах.

Интересную и перспективную, на наш взгляд, базу для построения высокоуровневых признаков несет в себе метод разложения на эмпирические моды (Empirical Mode Decomposition, EMD) Huang, et al. 1998-1999 [2-3]. Метод EMD в [2] был первоначально создан как инструмент для анализа нелинейных и нестационарных процессов, заданных одномерной кривой (далее 1D-EMD). С его помощью любую сигнатуру HSI можно разложить на конечное и часто небольшое число (например, 4-6 мод) функций внутренних мод (IMF) или просто эмпирических мод (EM), отражающих локальные свойства сигнатуры ( $f$ ) по каналам:

$$f(t) = r(t) + \sum_{i=1}^N \varphi_i(t), \quad (1)$$

где  $\varphi_i(t)$  - intrinsic mode function (IMF) или EM  $i$ -го порядка;  $r(t)$  – остаточный тренд. Первые моды содержат высокочастотные компоненты, а последние моды – низкочастотные компоненты разложения сигнала.

При анализе локальных свойств нелинейных нестационарных процессов значимыми оказываются мгновенные частоты разных масштабов параметра  $t$ . В результате EM могут фиксировать как небольшие мгновенные изменения, так и различные более медленные процессы, именуемые низкочастотными остатками ( $R$ ), и вычисляемые как среднее между огибающей максимумов  $U_f$  и огибающей минимумов  $L_f$ , которые заданы сплайнами:

$$R(t) = \frac{U_f + L_f}{2}, \text{ затем } \varphi(t) = f(t) - R(t) \quad (2)$$

Уже в статье [2] отмечалось, что локальное среднее  $R$ , вычисленное через огибающие, не является истинным средним, что может приводить к потере точности. В публикации [3] для решения данной проблемы предложено рассматривать три локальных масштаба времени: между последовательными пересечениями нуля моды; между последовательными экстремумами моды; между последовательными экстремумами кривизны функции. Но реально, это так и не сняло проблему. Тем не менее, метод считает, что на каждом шаге  $i$  разложения мы получаем приближенно ортогональные эмпирическую моду и низкочастотный остаток, т.е. приближенно равный нулю интеграл от их произведения:

$$\overline{\varphi_i(t) \cdot R_i(t)} = 0, \quad i \text{ -порядок моды и остатка.} \quad (3)$$

Довольно часто в практике анализа сигналов нелинейных нестационарных процессов корректность (3) удовлетворительна.

Довольно быстро метод 1D-EMD получил применение в задачах классификации HSI. Так уже публикация Xu, 2007 [4] исключает зашумленные каналы и использует для классификации HSI моды всех порядков и метрику spectral similarity value  $SSV_M = (1 - \rho)(Ed/r)$ , где  $\rho$  – коэффициент корреляции сигнатур HSI,  $Ed$  - Евклидово расстояние между ними,  $r$  - радиус, характерный для каждого класса. На данных Washington DC Mall достигнута величина Accuracy= 78,9%.

Вскоре после 1D-EMD появилось обобщение на двумерный случай (2D-EMD), и эти два метода стали использовать в комбинации. Интересная серия таких исследований в области классификации HSI выполнена в публикациях Demir et al, 2008 [5], 2010 [6], 2011 [7]. Характерно, что если в 1D-EMD для классификации старались больше применять старшие низкочастотные моды, рассматривая высокочастотные моды как носители шума, то в 2D-EMD для классификации стали применять первые 3 моды, а первые две особенно часто. В [5] показано, что сумма первых двух 2D-EMD мод вместо исходного изображения канала способна повысить среднюю точность классификации посредством SVM, для 9 из 16 размеченных классов HSI Indian Pine, с 92,67% до 99,49%. Это происходит за счет увеличения контрастности контура и мелких деталей объектов изображений, представленных в 1-й моде. В [6] сделан вывод о несостоятельности конкуренции 1D-EMD-SVM против 2D-EMD-SVM и даже просто SVM для изображений каналов HSI. В [7] решена проблема удаления шума в первой моде 2D-EMD средствами вейвлет-анализа.

В Erturk, 2013 [8] предложено для более уверенной классификации дополнить использование эмпирических мод 1D-EMD производной от исходной сигнатуры.

Публикация Zabalza (2014) [9], типично рассматривает первые 3 моды 1D-EMD как носители шума и использует их для выделения и удаления шума. Сравнивает такой метод удаления шума с удалением методом «Singular Spectrum Analysis (SSA)», путем отбрасывания членов сингулярного разложения после первых  $L$  наиболее значимых компонент. Для HSI Indian Pine удаление шума за счет первых 3 мод 1D-EMD не дало улучшения, а применение метода SSA позволило полностью подавить шум и улучшить точность классификации на 3%.

В публикации Pakhomov, et al., 2018 [10] предложена модификация вычисления низкочастотного остатка  $R_i$  как результата усреднения исходной функции  $f$  скользящим окном, изменяемым по результатам обработки очередной экстрагированной моды, вместо формулы (2):

$$R_i(j) = \frac{1}{w} \sum_{k=j-w/2}^{j+w/2} f_{i-1}(k); \quad \varphi_i = f_{i-1} - R_i, \quad i = 1, \dots, m \quad (4)$$

Приведены примеры вычисления 1D-EMD разложения на материале HSI Moffett Field.

В публикации Pakhomov, et al., 2020 [11], также на материале HSI Moffett Field, показано, что средняя величина коэффициента кросскорреляции для 1-ой, 2-ой и 3-ей EMs шести различных материалов является высокой, убывает с ростом номера моды, и равна соответственно: 0,9; 0,82; 0,74. Экстракция мод выполнялась по алгоритму [10]. Что говорит, вероятно, о существенном влиянии атмосферы на эти моды. Высказана гипотеза, что для большинства каналов первые EM это не шум, а выражение наиболее быстрых межканальных изменений в отражающих свойствах материалов.

В публикации Pukhkiy et al., 2023 [12] формализация алгоритма 1D-EMD [10] специализированного для анализа HSI развита рядом обновлений: 1) правилом расчета локального среднего при выходе окна за границу диапазона каналов; 2) возможностью уменьшить размер окна по сравнению с расстоянием между соседними пересечениями нуля в текущей EM; 3) подавлением шума в EMs за счет увеличения начального размера окна и кратности его применения. На 3-х HSI Moffett Field, Indian Pine, Cuprite, новый алгоритм 1D-EMD показал: 3-4-кратное увеличение числа мод; информационную эффективность первых мод; снижение уровня шума вплоть до отсутствия видимых шумов. Показано, что ширина окна усреднения для каждой EM является самостоятельным признаком классификации пикселя HSI. Построен аппарат визуального анализа HSI, использующий каналы троек EMs в качестве каналов RGB-визуализации. Отмечена возможность использования EMs и каналов 1D-EMD в качестве высокоуровневых признаков на спектрально специфичных данных.

Характеристику методов применяемых в многоклассовой классификации можно было бы начать с публикации Te-Ming Tu, et al. 1998 [13], отражающей типичный подход к классификации HSI. Этот подход заключается в радикальном сокращении числа каналов HSI применением метода PCA (Principal Component Analysis). PCA применяется на 1-й стадии для построения краткого списка каналов. На 2-й стадии происходит классификация ускоренным рекурсивным методом максимального правдоподобия (MLC, Maximum likelihood classification). Благодаря PCA и быстрой рекурсии достигнуто ускорение в 30-145 раз по сравнению с обычным MLC. В публикации Deniz Erdogmus, et al. 2004 [14] представлен быстрый алгоритм PCA. Возможность быстрого трекинга обеспечивается рекурсивным характером полного обновления матрицы собственных векторов. Публикация Пестунова, 2015 [15], предлагает блочный метод главных компонент для выделения информативных признаков при классификации гиперспектральных изображений. Смысл блочности заключается в отдельном PCA-анализе выраженных диапазонов спектральной кривой: видимого, ближнего и среднего инфракрасных. Результаты PCA на этих диапазонах по-отдельности существенно различаются.

В статье Chen Y. et al., 2015 [16] поставлены вопросы, касающиеся экстракции признаков (FE) классификации с использованием глубокой сети (DBN, deep belief network), со спектральными признаками, пространственными признаками и спектрально-спектральными признаками. Предложена новая глубокая архитектура, которая сочетает в себе спектрально-пространственную FE и классификацию для получения высокой точности классификации. Структура представляет собой гибридный анализ главных компонент (PCA), иерархической FE на основе обучения и логистической регрессии (LR).

В статье R.V. & M.P. 2020 [17] предложен метод классификации HSI, который включает рекурсивный фильтр, сохраняющий структуру изображения при удалении шума (SPRF), и вероятностный анализ главных компонент (PPCA) для сокращения размерности.

Публикации этого года Uchaev, et al. 2023[18] и Md Rashedul Islam, et al. 2023[19] все также предлагают для классификации HSI использовать триаду: 1) PCA – для резкого сокращения числа каналов; 2) SVM (машину опорных векторов) в качестве метода искусственного интеллекта; 3) некоторую предварительную фильтрацию, например, с минимальной шумовой фракцией (MNF) или стратегию перекрестной кумулятивной остаточной энтропии (CCRE), для повышения надежности решения.

В итоге отметим, что: 1) в многоклассовой классификации HSI в качестве признаков применяются как исходные сигнатуры пикселей, так и их 1D-EMD эмпирические моды и/или отдельные каналы и их 2D-EMD эмпирические моды; 2) в решении задачи классификации утвердился рекурсивный подход, использующий также метод PCA для резкого сокращения размерности. Возьмем этот подход, за исключением 2D-EMD и обязательности PCA, за основу нашей реализации классификации HSI ДЗЗ с помощью высокоуровневых признаков на основе эмпирических мод. Нашей целью будет исследование построения высокоуровневых признаков исключительно на основе 1D-EMD мод, для того, чтобы максимально использовать гиперспектральность изображений.

## 2. Материалы и методы

### 2.1. Гиперспектральное изображение и эталоны объектов классификации

Данное исследование выполнено с использованием данных гиперспектрального изображения Moffett Field (рисунок 1). Выбор данного изображения обусловлен его выдающимся статусом среди прочих свободно доступных гиперспектральных изображений благодаря наличию множества разнообразных объектов, совмещенных на одном изображении. Moffett Field является первым в Соединенных Штатах Америки заповедником водно-болотных угодий, органично вписанным в городскую среду. Это место предоставляет уникальную возможность для выявления спектральных характеристик даже незначительных вариаций объектов в городской и природной среде на основе анализа их спектральных характеристик. HSI Moffett Field обладает следующими техническими параметрами: 224 спектральных канала, охватывающих диапазон длин волн от 360 до 2500 нм; разрешение изображения 1924x753

пикселей (общее количество пикселей - 1446848, число пикселей находящиеся в зоне сканирования - 1380437); пространственное разрешение 17,5 м/пикс; и объем занимаемой изображением памяти 633,84 мегабайта.

Ввиду обширного многообразия однородных объектов, например таких как водные угодья, настоящее изображение приобретает особое значение в контексте кластеризации. Особенно сложной задачей является способность эффективно разделять не только водные элементы от наземных, но и осуществлять верное разграничение между самих водных объектов.



**Рисунок 1** – Цветовое представление гиперспектрального изображения Moffett Field














Во всех проводимых экспериментах будет использоваться лишь часть спектрального диапазона данного изображения. Присутствие значительного количества водяного пара в атмосфере Земли делает её оптически плотной средой для определенных длин волн, что приводит к заметному уровню шума в некоторых каналах. Атмосфера сильно поглощает свет преимущественно в диапазоне длин волн от 1250 нм до 1600 нм. Исходя из этого, из эксперимента были исключены каналы с 94-го по 131-й, которые соответствуют диапазону 1250-1600 нм.

Объекты классификации HSI Moffett Field показаны на рисунке 2 и описаны в таблице 1. Места взятия 16 образцов для исследования выбраны и помечены вручную. Цель выбора - создать для исследования 2 группы классов: со значительным расстоянием между образцами и с незначительным расстоянием между образцами.



**Рисунок 2** – Места выбора образцов для исследования высокоуровневых признаков классификации

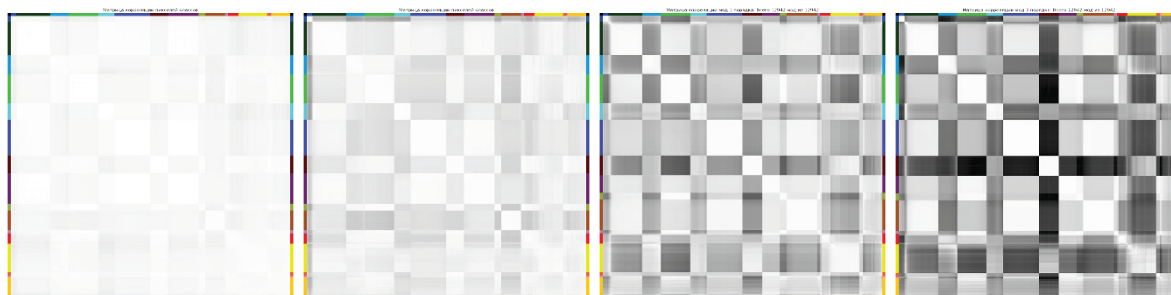
**Таблица 1** - Исследуемые объекты и центры выборки их образцов

№	Материал подстилающей поверхности образца	Координаты сигнатуры (у, х)	Назначенный цвет класса
1	Вода морская на фарватере	540, 470	
2	Приливные загрязнения	427, 774	
3	Болота 1	288, 758	
4	Грунт (без растительности)	154, 834	
5	Растительность (пл.д/гольфа)	93, 1137	
6	Бетон (твердые породы)	315, 1334	
7	Соляной испарительный пруд1	335, 1360	
8	Соляной испарительный пруд2	305, 1280	
9	Асфальт	278, 606	
10	Озёра 1	142, 704	
11	Растительность (деревья)	18, 811	
12	Крыши	365, 1431	
13	Мелководье	183, 1208	
14	Озёра 2	59, 1098	
15	Соляной испарительный пруд3	241, 1299	
16	Болота 2	707, 1810	

Референсные сигнатуры материалов с 1-й по 16-ю были установлены путем вычисления среднего значения в выборке, охватывающей окно 3x3 пикселя, с центром в пикселе с координатами указанными в таблице 1.

## 2.2. Анализ классов и конструирование высокоуровневых признаков. Выбор метрик

Спектр отражения - является уникальной характеристикой, "подписью" (сигнатурой) материала, и может использоваться для идентификации материала по одному пикселю часто даже без его контекста. Тем не менее, проблема конструирования высокоуровневых признаков и особенно спектрально специфичных остается до сих пор актуальной, несмотря на присутствие ряда публикаций. Поясним причину, опираясь на матрицы кросскорреляции построенные по равномерно распределенным выборкам пикселей из 16 размеченных классов HSI Moffett Field (рисунок 3).




**Рисунок 3** - Матрицы кросскорреляции для 16 классов (слева-направо): 1) для исходных сигнатур HSI Moffett Field; 2) для них же, но без рэлеевского рассеяния; 3) для 1-ой ЕМ; 4) для 3-ой ЕМ. [12]

Для 1-ой матрицы на изображении слева вообще не видно класса, который мог бы быть выделен однозначно. После удаления рэлеевского рассеяния (2-я матрица) уже появился класс, который может быть однозначно выделен (самый яркий по строке и столбцу). В 3-й матрице таких классов около половины (их 9), а в 4-й - уже почти все. В итоге очевидно, что уровень

первых мод как признаков качественно выше, чем даже у сигнатур рэлеевского рассеяния (далее «чистых сигнатур»). Но и это еще не полное решение, т.к. в одном пикселе могут встретиться спектры сразу нескольких объектов/материалов в разных пропорциях и шум.

С целью дополнительного обогащения спектральных характеристик исходной сигнатуры пикселей предусмотрена конкатенация к ней ее эмпирической моды/мод. При конкатенации операнды должны быть центрированы и нормализованы на стандартные отклонения.

Обычно для класса выбирается угловая метрика. Для понимания старта рекурсии необходимо построить матрицу расстояний, угловых или евклидовых, между образцами/эталоном классов.

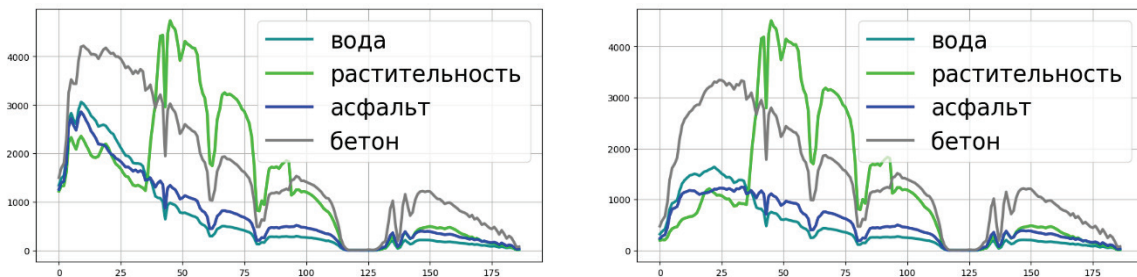


**Рисунок 4** – Матрицы взаимных угловых расстояний (в гадусах) для 16 эталонов: слева – для «чистых» сигнатур пикселей; справа – для конкатенации 1-й и 4-й ЭМ этих сигнатур. Лидеры: слева – класс «деревья», справа - класс «соляной пруд 2»

Из матриц видно, что для эталона на «чистой» сигнатуре классы гораздо менее контрастны, чем на эталоне-конкатенации мод. При выборе порога для членов класса 0.95 (18.19°) многие пары эталонов слева окажутся неразличимыми. Таких пар 50 из 240 недиагональных элементов. В правой матрице таких пар всего 12 из 240 (в 4 раза меньше). Таким образом, добавлением мод мы можем сделать эталоны существенно более различимыми.

Рисунок 5 поясняет большие и малые углы между сигнатурами (слева) и их изменение при вычитании рэлеевского рассеяния (справа). Слева представлены 4 эталонных сигнатуры для воды, асфальта, бетона и растительности. Из формы кривых видно, что евклидово и угловое расстояние между эталонами Асфальт и Вода мало, несмотря на их различную природу. Растительность далека от всех 3 остальных и по евклидовой, и по угловой метрике. Бетон далек от 3 остальных по евклидовой метрике, но близок к воде и асфальту по угловой.

Частично в контрастировании различий между асфальтом и водой может помочь вычитание рэлеевского рассеяния (сине-голубое сияние дневного неба, дающее одинаковый вклад во все пиксели) (рисунок 5, справа). Значения евклидовых расстояний в этом случае сохранились, но угловые расстояния стали заметно больше (таблица 2).



**Рисунок 5** – 4 исходных эталонных сигнатуры (слева), и они же за вычетом рэлеевского рассеяния (справа)

Сигнатуры подобные друг-другу совпадают в угловой мере. Поэтому эталоны слева вода, асфальт, бетон сложноразличимы в угловой метрике. После вычитания рэлеевского рассеяния они становятся заметно более различимы. Например, угол «вода-асфальт»: слева – 10.9°, справа – 18.2° (см. таблицу 2).

**Таблица 2** – Расстояние и косинус угла (угол) между эталонами классов воды, растительности и асфальта

Рэлеевское рассеяние	Расстояние	вода - растительность	асфальт - растительность	вода - асфальт
Не вычтено	Евклидово	19499	17230	2834
	Косинус угла	0.681 (47.1°)	0.793 (37.5°)	0.982 (10.9°)
Вычтено	Евклидово	19499	17230	2834
	Косинус угла	0.603 (52.9°)	0.799 (37.0°)	0.950 (18.2°)

### 2.3. Рекурсивный метод сегментации классов на основе эмпирических мод

Обозначим через  $E = \{E_1, \dots, E_K\}$  набор стартовых эталонов классов, где  $K$  - число выбранных эталонов. Число координат ( $N$ ) в векторе сигнатуры эталона зависит от числа используемых каналов гиперспектрального изображения. Стартовый  $E$  содержит референсные сигнатуры классов.

Взаимные расстояния между эталонами определяются матрицей  $D_K$  (6) (см. также Рис.4). Каждый элемент матрицы — это расстояние между парой эталонов, соответствующих строке  $r$  и столбцу  $c$ . Матрица является симметричной по отношению к главной диагонали.

$$D_K = \begin{bmatrix} d_{1,1} & \dots & d_{1,K} \\ \vdots & \ddots & \vdots \\ d_{K,1} & \dots & d_{K,K} \end{bmatrix}, \quad (6)$$

где каждое  $d_{r,c}$  — это расстояние между эталонами.

Метод рекурсивной классификации предлагает последовательно исключать из матрицы эталон за эталоном, каждый раз выбирая эталон  $E_k$  с максимальным расстоянием  $d_{max}$  до остальных классов:

$$d_{max} = \max_r \min_c (d_{r,c}) \quad (7)$$

Величина  $d_{max}$  задает масштаб отсчета для определения границ класса с эталоном в центре. Для управления границей класса использован параметр  $\delta$ , который определяет в итоге границу:

$$d_{class} = d_{max} * \delta. \quad (8)$$

Все пиксели, находящиеся в радиусе  $d_{class}$ , маркируются классом, к которому принадлежит эталон, и образуют маску, исключаящую класс из дальнейшей рекурсии. Таким образом, в результате уменьшения количества эталонов появляется возможность разделять классы по всё более слабо выраженному признаку (угловому или евклидову расстоянию).

Алгоритм воспроизводится до тех пор, пока  $K > 2$ . В случае, когда значение  $K = 2$ , выполняется разметка пикселей этих двух классов, для которых применяется  $\delta = 0.5$ .

В эксперименте, за исключением последних двух классов, будем использовать  $\delta \in [0.75, 0.85]$ .

Фактически на каждом шаге рекурсии решается задача бинарной классификации: поиск класса наиболее удаленного от других классов.

Вопрос состоит также в том, что именно мы будем считать эталоном класса при желании повысить уровень эталона как признака класса и что изменять для того, чтобы максимизировать расстояние до остальных эталонов.

Для решения данной проблемы предлагается в качестве эталона класса исследовать следующие его формы:

1. референсная сигнатура ( $f$ ) образца класса



2. референсная сигнатура ( $f$ ) образца класса за вычетом рэлеевского рассеяния ( $r_R$ )
3. референсная сигнатура ( $f$ ) образца класса дополненная одной ее эмпирической модой ( $\varphi$ ) путем конкатенации к исходной сигнатуре  $f$
4. конкатенация нормализованных мод (без исходной сигнатуры  $f$ ).

## 2.4. Метод разложения на эмпирические моды

Рассмотрим версию алгоритма алгоритм 1D-EMD ориентированную на HSI [12].

*Алгоритм 1D-EMD:*

- 1) Спектральная характеристика (сигнатура) пикселя HSI на первом шаге алгоритма  $i := 1$ ,  $i$  – номер шага, определяется как дискретная функция  $f_{i-1}(j)$  от номера канала  $j \in [1, N]$ . Процедура разложения организуется как рекурсия вычисления  $i$ -той эмпирической моды, в виде разности между  $f_{i-1}(j)$  и результатом ее сглаживания окном (шириной  $w$ ), который рассматривается как  $i$ -тый низкочастотный остаток разложения ( $R_i$ ).
- 2) Вычисление низкочастотного остатка  $R_i$  и эмпирической моды на шаге  $i$ :

$$R_i(j) = \frac{1}{w} \sum_{k=j-w/2}^{j+w/2} f_{i-1}(k); \quad \varphi_i = f_{i-1} - R_i \quad (5)$$

Для номеров каналов, оказавшихся за пределами области определения,  $k < 1$  и  $k > N$ , значения  $f_{i-1}(k)$  принимаются равными ее значениям на границах (для увеличения веса точки на границе открытого интервала).

- 3) Анализ параметров очередной моды: общее число  $n = n_{max} + n_{min}$  и точки экстремумов; число  $n_{zeros}$  и координаты точек пересечений нуля; контроль  $\max$  числа экстремумов  $n_{z-z} > 1$  между соседними пересечениями нуля; минимальное расстояние между соседними минимумами  $d_{min}$  и соседними максимумами  $d_{max}$ ;  $d = \min(d_{min}, d_{max})$ .
- 4) Если  $n > 3$ , то обновляется значение  $w = 2[d/2] + 1$ ,  $f_{i-1} := R_i$ ,  $i := i + 1$  и повторяются пункты 2)-4).
- 5) Иначе,  $r = R_i$  и процедура завершается.

Алгоритм выполняется независимо для каждого пикселя HSI.

Стартовое значение  $w$  выбирается в интересах борьбы с шумом на старте декомпозиции. По умолчанию стартовое значение  $w=3$  (минимальное). Параметр на старте может принимать и заметно большие значения, например 7. Может быть назначено число повторений стартового размера окна. Но алгоритм сохраняет, благодаря правилу (5) для вычисления  $R_i$ , возможность вернуться к меньшим размерам окна, если процессы такого временного масштаба присутствуют и после стартового сглаживания. Подчеркнем, что алгоритм отличается от классического [2-3] методом вычисления локального среднего  $R_i$  и вариацией ширины окна на старте.

## 3. Анализ результатов экспериментов

Для гиперспектрального изображения Moffett Field, и взятых из него образцов 16 классов, исследованы три вида рекурсивной классификации, использующих следующие высокоуровневые признаки в составе эталона класса:

- 1) Эталон - референсная сигнатура HSI пикселя за вычетом рэлеевского рассеяния;
- 2) Эталон - референсная сигнатура HSI пикселя, дополненная ее эмпирической модой третьего порядка
- 3) Эталон - эмпирическая мода первого порядка, дополненная модой четвёртого порядка

Случай «эталон - референсная сигнатура образца класса» мы исключили из эксперимента из-за заведомо худших ожидаемых результатов.

Образцы назначены вручную с целью создать 2 группы классов: со значительным расстоянием между образцами и с незначительным расстоянием между образцами. Из матрицы угловых расстояний между эталонами (рисунок 4, слева) видим, что к группе 2 относятся:

двойники воды: мелководье (4°), озера 2 (7°), болота 1 (14°), соляной пруд 1 (17°), также образующие между собой плотные пары, например, мелководье-озера 2 (8°); двойник растительности: деревья (6°); неестественные соседи загрязнений: асфальт (12°), бетон (15°), крыши (17°), также образующие между собой естественные плотные пары: бетон-асфальт (4°), бетон-крыши (5°); неестественные соседи воды: асфальт (18°), крыши (18°), бетон (19°).

В экспериментах мы будем наблюдать как проявляются и изменяются эти связи с повышением уровня эталона.

В конце каждого эксперимента получалось HSI изображение сегментированное на 16 классов с классификационной раскраской. Пиксели за пределами зоны сканирования при сегментации не рассматривались. Фиксировались пиксели оставшиеся вне классификации из-за расширения исходного эталона модами.


### 3.1. Эталон - референсная сигнатура за вычетом рэлеевского рассеяния

В случае классификации по эталону – «чистая» референсная сигнатура, используя в качестве меры близости евклидово расстояние, получаем классификацию с рядом неточностей в основном из-за близости 4 сигнатур (см. выше) мелководья, асфальта, бетона и загрязнений (рисунок 6). Видно, как берег залива на месте мелководья и загрязнений закрашен соответственно серым и синим цветом, которые относятся к классу бетона и асфальта соответственно.



**Рисунок 6** – Классификация 16 классов, эталон-референсная сигнатура за вычетом рэлеевского рассеяния, по евклидовым расстояниям ( $\delta = 0.8$ ). Количество неклассифицированных пикселей 1.26% от площади сканирования

На рисунке 7 показан результат классификации для эталонов из «чистых» референсных сигнатур за вычетом рэлеевского рассеяния. Близость к эталону определяется по угловому расстоянию.



**Рисунок 7** – Классификация 16 классов для эталонов-исходных сигнатур, с помощью матрицы углов

В классификации присутствуют неточности связанные с близостью классов: загрязнение и бетон (залит цветом загрязнения); соляной пруд 1, мелководье и озёра 2 (желтый цвет класса соляной пруд1); озёра 2 и вода (темно-синий цвет класса озёра 2).

Эксперимент «эталон - референсная сигнатура за вычетом рэлеевского рассеяния» показывает, что такие эталоны на материале HSI Moffett Field не обладают свойствами высокоуровневых признаков.

### 3.2. Эталон - референсная сигнатура, дополненная ее эмпирической модой третьего порядка

Эталон - референсная сигнатура, дополненная ее эмпирической модой третьего порядка, мера близости к эталону - евклидово расстояние. Результат стал значительно лучше (рисунок 8). Эталоны классов асфальт и бетон (взлетные полосы аэродрома, природный камень, строительные сооружения) правильно отображены и отделены от водных классов. Также, эталон деревьев и загрязнений практически соответствуют своему классу. Класс мелководье окрашен желтым цветом класса *соляной пруд 1*.



**Рисунок 8** – Классификация 16 классов, эталон - конкатенация референсной сигнатуры и ее 3-й моды, мера близости к эталону - евклидово расстояние ( $\delta = 0.8$ ). Неклассифицированные пикселей - 0.98% сканирования

### 3.3. Эталон - эмпирическая мода первого порядка, дополненная модой четвёртого порядка


Эталон – конкатенация 1 и 4 мод, мера близости к эталону - евклидово расстояние (рисунок 9).



**Рисунок 9** - Классификация 16 классов, эталон - конкатенация 1-й и 4-й мод, мера близости к эталону - евклидово расстояние ( $\delta = 0.8$ ). Количество неклассифицированных пикселей 7.72% от площади сканирования


Класс асфальта более адекватен, как и дорожные покрытия. Разделены классы твёрдых пород, асфальта, водных объектов.

На рисунке 10 показано изображение, каждый пиксель которого отображает среднее значение по каналам пикселя HSI за вычетом рэлеевского рассеяния. Эти величины, как и другие статистические характеристики пикселей HSI, также можно использовать в векторе высокоуровневых признаков, использовать как дополнение к угловым метрикам.



**Рисунок 10** - Изображение в средних по по каналам HSI за вычетом рэлеевского рассеяния

На рисунке 11 представлен результат классификации на 16 классов, эталон - конкатенация 1-й и 4-й мод, мера близости к эталону - угловое расстояние ( $\delta = 0.8$ ). Корректно классифицированы солевые озера, болота, вода, мелководье. Под эталон класса «деревья» собраны и деревья, и растительность площадок для гольфа. Это сигнал для их объединения в один класс. Под эталон класса асфальт собраны классы асфальта и бетона, включая скальные породы. Это следствие отсутствия в высокоуровневом признаке-эталоне референсной сигнатуры или низкочастотного остатка одной из мод.



**Рисунок 11** – Классификация 16 классов, эталон - конкатенация 1-й и 4-й мод, мера близости к эталону - угловое расстояние ( $\delta = 0.8$ ). Количество неклассифицированных пикселей 9.55% сканирования

**Таблица 4** – Временные оценки (сек) алгоритмов

Вариант алгоритма рекурсивной классификации	Время исполнения EMD	Время на EMD и сегментацию	Общее время работы
Исходные сигнатуры HSI	0	17.34	17.34
	117.09	32.16	149.25

Временные характеристики получены для следующей аппаратной конфигурации: Intel Core i3-8130U, 2.2 GHz, 4 cores, 4 GB

## Заключение

Исследована роль эмпирических мод в синтезе высокоуровневых признаков для классификации гиперспектральных изображений ДЗЗ. Исследования выполнены на материале известного гиперспектрального изображения (HSI) Moffett Field. Этот источник выбран по причине его очень высокой классификационной сложности. На HSI Moffett Field присутствуют одновременно заповедник водно-болотных угодий, во всем их многообразии, расположенный вокруг части залива Сан-Франциско, и окружающая заповедник городская среда ближайшего города Сан-Хосе. Исследована классификация 16 классов объектов, представленных референсными сигнатурами: 9 водно-болотных объектов (вода залива на факватере, мелководье, 2 типа озер, 2 типа болот, 3 типа соляных испарительных прудов); растительность, деревья; приливные загрязнения; асфальт, бетон, крыши, почва без растительности.

В качестве источника повышения уровня признаков для классификации HSI предложены и исследованы первые эмпирические моды разложения спектральной характеристики пикселя HSI на эмпирические моды (EMD, empirical mode decomposition).

Установлено следующее:

- 1) Эталон класса в форме только в форме референсной сигнатуры образца класса не может быть признаком достаточным для классификации на полном изображении Moffett Field.
- 2) Дополнение эталона класса, состоящего из референсной сигнатуры (спектральной характеристики) образца класса, даже одной из первых эмпирических мод, либо кардинальным образом увеличивает контрастность эталона, либо выявляет принадлежность к одному классу (неразличимость эталона в глобальной системе координат).
- 3) Для классов удаленных друг от друга возможно применять в качестве высокоуровневого признака конкатенацию одних только первых мод без референсной сигнатуры.
- 4) Повышение уровня признаков путем присоединения дополнительных мод приводит к некоторому сужению определяемого класса.
- 5) Экспериментальное программное обеспечение (ПО) построено по принципу жадного рекурсивного классификатора. Оно может быть доработано в качестве ПО для спектрально специфической кластеризации и классификации HSI.

Статью отличает подход к формированию высокоуровневых признаков классификации на основе именно спектрально специфицированных признаков.

## СПИСОК ИСТОЧНИКОВ

- [1] Pan E, Ma Y, Fan F, Mei X, Huang J. Hyperspectral Image Classification across Different Datasets: A Generalization to Unseen Categories. *Remote Sens.* 2021, 13, 1672. doi.org/10.3390/rs13091672.
- [2] Huang, N.E. The Empirical Mode Decomposition and Hilbert Spectrum for nonlinear and non-stationary time series analysis / Huang, N.E., Shen, Z., Long, S., Wu, M.C., Shih, H.H., Zheng, Q., Yen, N.-C., Tung, C. C., Liu, H. H., // *Proc. R. Soc. London A*, 454, 1998, 903-995.
- [3] Huang, N.E., Shen, Z., and Long, S. R. "A new view of nonlinear water waves: the Hilbert spectrum," *Annual Review of Fluid Mechanics*, vol. 31, pp. 417-457, 1999. <https://doi.org/10.1146/annurev.fluid.31.1.417>.
- [4] Xu, Y.P.; Hu, K.N.; Han, J.X. Classification based on the EMD of hyperspectral curve. *Proc. SPIE* 2007, 6795. <https://doi.org/10.1117/12.774539>.

- [5] Demir, B. and Ertürk, S. (2008). Empirical Mode Decomposition Pre-Process for Higher Accuracy Hyperspectral Image Classification // IGARSS 2008 - 2008 IEEE International Geoscience and Remote Sensing Symposium. doi:10.1109/igarss.2008.4779150.
- [6] Demir, B. and Ertürk, S. Empirical Mode Decomposition of Hyperspectral Images for Support Vector Machine Classification // IEEE Transactions on Geoscience and Remote Sensing, vol. 48, no. 11, pp. 4071-4084, 2010, doi: 10.1109/TGRS.2010.2070510.
- [7] Demir, B., Ertürk, S., Güllü, M.K.: Hyperspectral Image Classification Using Denoising of Intrinsic Mode Functions. IEEE Geosci. Remote Sens. Letters, 8(2), 220–224 (2011), doi: 10.1109/LGRS.2010.2058996.
- [8] Erturk, A.; Gullu, M.K.; Erturk, S. Hyperspectral image classification using empirical mode decomposition with spectral gradient enhancement. IEEE Trans. Geosci. Remote Sens. 2013, 51, 2787–2798.
- [9] Zabalza, J. et al. "Singular Spectrum Analysis for Effective Feature Extraction in Hyperspectral Imaging // IEEE Geoscience and Remote Sensing Letters, vol. 11, no. 11, pp. 1886-1890, Nov. 2014, doi: 10.1109/LGRS.2014.2312754.
- [10] Pakhomov, P.A., Borusyak, A.V., Turlapov, V.E. Investigation of hyperspectral image pixel signatures by the empirical mode decomposition method //CEUR Workshop Proceedings V.2210, 2018, P. 352-364.
- [11] Pahomov, P. and Turlapov, V. Investigation of correlation of empirical modes and low-frequency residues of hyperspectral image signatures // 2020 International Conference on Information Technology and Nanotechnology (ITNT), Samara, Russia, 2020, pp.1-5, <https://doi.org/10.1109/ITNT49337.2020.9253179>.
- [12] Empirical mode decomposition method in the analysis of hyperspectral images / Pukhkiy K.K., Pakhomov P.A., Getmanskaya A.A., Vasiliev E.P., Utesheva T.Sh., Turlapov V.E./ ArXiv, 2023. -17pp.
- [13] Te-Ming Tu, et al. A Fast Two-Stage Classification Method for High-Dimensional Remote Sensing Data. IEEE transactions on geoscience and remote sensing, V. 36, No. 1, January 1998, pp.182-191. <https://doi.org/10.1109/36.655328>.
- [14] Recursive principal components analysis using eigenvector matrix perturbation / Deniz Erdogmus, Yadunandana N. Rao, Hemanth Peddaneni, Anant Hegde, Jose. C. Principe / EURASIP Journal on Advances in Signal Processing 2004. 263984. <https://doi.org/10.1155/S1110865704404120>.
- [15] Пестунов И.А., Мельников П.В. Блочный метод главных компонент для выделения информативных признаков при классификации гиперспектральных изображений // Журнал Сибирского федерального университета. Серия «Техника и технологии». 2015, 8 (6). С.715-725. URL: <https://elibr.sfu-kras.ru/handle/2311/19837>.
- [16] Chen Y., Zhao X. and Jia X. "Spectral–Spatial Classification of Hyperspectral Data Based on Deep Belief Network," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 8, no. 6, pp. 2381-2392, June 2015 URL: <https://doi.org/10.1109/JSTARS.2015.2388577>.
- [17] R, V. & M, P. (2020). Probabilistic PCA Based Hyper Spectral Image Classification for Remote Sensing Applications. Advances in Intelligent Systems and Computing Intelligent Systems Design and Applications: 863–869. [https://doi.org/10.1007/978-3-030-16660-1\\_84](https://doi.org/10.1007/978-3-030-16660-1_84).
- [18] Uchaev Denis; Uchaev, Dmitry. Small Sample Hyperspectral Image Classification Based on the Random Patches Network and Recursive Filtering. Sensors 2023, 23(5), 2499; <https://doi.org/10.3390/s23052499>.
- [19] Md Rashedul Islam, Ayasha Siddiqa, Masud Ibn Afjal, Md Palash Uddin and Anwaar Ulhaq. Hyperspectral Image Classification via Information Theoretic Dimension Reduction. Remote Sens. 2023, 15(4), 1147; <https://doi.org/10.3390/rs15041147>.