

Исследование и разметка объектов гиперспектральных изображений для машинного обучения

В.П. Громов¹, Л.И. Лебедев¹, В.Е. Турлапов¹

¹Национальный исследовательский государственный университет им. Н.И. Лобачевского, пр. Гагарина 23, Нижний Новгород, Россия, 603952

Аннотация. Обсуждается модификация номинальной последовательности шагов по анализу ГСИ, предложенной Landgrebe, необходимая в условиях появления библиотек опорных сигнатур, необходимых для мониторинга окружающей среды. Подход основан на рассмотрении пикселя ГСИ как сигнатуры, хранящей все спектральные признаки как объекта и его состояния, а ГСИ в целом - как двумерного поля сигнатур. В качестве первого шага анализа предлагается процедура детектирования линейной зависимости сигнатур по величине коэффициента корреляции Пирсона. Основным аппаратом анализа также, как и по Landgrebe, является метод главных компонент, но он используется уже не для построения классов, а для исследования наличия в классе подклассов, существенных для прикладной области. Экспериментальный материал включает объекты: вода, болота, грунт, растительность, бетон, загрязнения. Выделение образцов объекта на изображении производится интерактивно пользователем. Из исследованных образцов объектов ГСИ формируется база эталонов для классов (подклассов) объектов, которая в свою очередь может использоваться для автоматизации разметки ГСИ с целью применения методов машинного обучения для распознавания объектов ГСИ и их состояний.

1. Введение

Для успеха развития и полноты применения гиперспектральных изображений (ГСИ) необходим уровень автоматизации обработки, демонстрируемый сегодня примерами успешного применения методов искусственного интеллекта, в частности, методов глубокого обучения. Однако этот успех методов глубокого обучения в неменьшей мере определяется полнотой исследования и формализации объектов ГСИ, подлежащих распознаванию и количественной оценке в каждой прикладной задаче. Все это делает актуальным исследование классов объектов с целью формирования эффективного набора эталонов (дескрипторов) класса и баз знаний (библиотек эталонов классов объектов и их состояний), обеспечивающих стадии обучения и работы методов искусственного интеллекта.

Необходимой функцией такой библиотеки классов ГСИ должна быть функция автоматической разметки объектов на каждом новом обучающем ГСИ для каждого новых условий прикладной задачи. В целом ряде прикладных задач объект ГСИ имеет еще и сезонно-временные состояния и свойства, что кратно усложняет задачу, требует создания инструмента способного различать малые изменения классифицируемого объекта. Одним из возможных кандидатов на такой инструмент может быть метод главных компонент, широко применяемый сегодня в обработке ГСИ для минимизации размерности базиса представления исследуемого класса. Данная работа

посвящена осмыслению аппарата анализа ГСИ, который способен обеспечить подготовку адекватного описания иерархии классов ГСИ, а также созданию, реализации и демонстрации работоспособности алгоритмического и программного обеспечения для этих целей.

2. Обзор публикаций по теме исследования

Содержание данной работы определено целым рядом публикаций последних лет. Однако начать хочется с публикации [1] 20-летней давности, в которой автор, D.Landgrebe, подводит итоги за более чем 20-летний период своей работы в исследовании дистанционного зондирования Земли (ДЗЗ). Landgrebe начал исследования с мультиспектральных изображений (МСИ) Земли и является одним из двух авторов известного открытого программного комплекса MultiSpec для обработки данных ДЗЗ, расширенного затем до обработки ГСИ и остающегося популярным в мире до настоящего времени. Этот комплекс используется и в России, например, в GIS-Lab при МГУ. Свежая версия комплекса (<https://engineering.purdue.edu/~biehl/MultiSpec/>) доступна на сайте университета авторов.

В [1] Landgrebe как итог исследования МСИ и ГСИ устанавливает приоритет спектральных признаков объекта над признаками, связанными с пространственным соседством пикселей, как не требующих исследования такого соседства. Здесь же он сформулировал требования к оптимальной определенности класса, а значит и к инструменту (программному комплексу), с помощью которого достигается такая определенность. Оптимальная определенность класса по Landgrebe требует, чтобы определения (признаки) класса были:

- *Исчерпывающими*. Должен быть логический класс для назначения соответствия каждого пикселя в сцене.
- *Обеспечивающими разделимость*. Классы должны быть в достаточной степени отделены прежде всего с точки зрения имеющихся спектральных характеристик.
- *Информационно ценными*. Классы должны быть теми, которые соответствуют потребностям пользователей.

В этой же работе Landgrebe предложил номинальную последовательность шагов по анализу гиперспектральных изображений из 4 шагов, которая при необходимости может итеративно повторяться:

- 1) Разграничение классов и формирование образцов для обучения
- 2) Извлечение признаков и предварительная классификация
- 3) Окончательное определение описателей класса
- 4) Классификация.

На первом шаге на основе визуального восприятия и выделения образцов однородных объектов, принадлежащих классу (подклассу), формируются признаки каждого класса, максимально задействуя спектральные признаки.

Практика применения второго шага предполагает, что тренировочные наборы определенные для класса могут оказаться небольшими. Из чего сделан вывод, что полезно исключить признаки, которые неэффективны для конкретного набора классов, и одновременно уменьшить размерность признаков без потери информации. Предварительная классификация является критерием успешности извлечения признаков и может направлять расширение как состава признаков, так и обучающей выборки. В качестве основной процедуры формирования совокупности признаков использован метод главных компонент, как один из основных способов уменьшить размерность данных, потеряв наименьшее количество информации. Предложенная Landgrebe номинальная последовательность шагов по анализу ГСИ в основном сохраняет свою актуальность до настоящего времени.

Однако, наиболее важным результатом многолетних исследований Landgrebe на наш взгляд является вывод о том, что, из-за влияния атмосферы, наилучшей точностью ГСИ, на которую мы можем рассчитывать, является точность от 2 до 5% (не точностью аппаратуры фиксации ГСИ, а точностью соответствия зафиксированного отражения земной поверхности реальному отражению), что не может сравниться даже с уровнем измерения 0,1%, подразумеваемым 10-битовыми данными. К сожалению, Landgrebe не указывает правила оценки этих 2-5%, но это вселяет надежду, что во многих случаях можно было бы ограничиться однобайтовым

представлением ГСИ вместо двухбайтового, и говорит о полезности наличия среди обеспечения анализа ГСИ инструментов для оценки шумовой составляющей, например, на основе метода эмпирических мод [2].

Вместе с тем, публикации последних лет обращаются к построению библиотек опорных спектральных сигнатур ГСИ, обеспечивающих автоматизацию классификации объектов ГСИ в прикладных задачах. Так в публикации [3] 2014 года подчеркивается необходимость создания базы данных опорных спектральных сигнатур ГСИ для объектов с разными типами загрязнений. Это планируется использовать для создания классификационных карт участков загрязнений и мониторинга окружающей среды по данным ГСИ. Классификация «с обучением» использует базу данных сигнатур загрязнителей, что значительно ускоряет и упрощает дальнейшую работу. Проведено испытание по выявлению участков с присутствием нефтяных загрязнений. В публикации [4] 2017 года авторы дополнили метод двухэтапным разбиением на кластеры внутри каждого класса: на первом этапе алгоритм выполняет кластеризацию областей интереса, максимизируя функцию правдоподобия для смеси гауссовских распределений; на втором - выполняет кластеризацию, используя расстояния Махаланобиса до центров кластеров в качестве признакового пространства.

Обнаружение аномалий на гиперспектральных изображениях является задачей очень близкой к задаче детектирования различных состояний объекта. В публикации [5] 2014 года предложен ряд новых алгоритмов обнаружения аномалий на ГСИ: алгоритмы спектрального рассогласования (пространственно-спектральный и адаптивный спектральный с модификацией) и алгоритм вероятностного обнаружения аномалий. Алгоритмы спектрального рассогласования используют для определения факта «аномальности» рассогласование статистики данных внутреннего окна с данными внешнего окна. Алгоритм вероятностного обнаружения аномалий использует переключивание спектральных данных сигнатур на существенно меньшее число уровней (в примере – на 4 уровня). Проведено сравнение предложенных алгоритмов с широко используемыми вариантами RXD-алгоритма (глобальным и локальным), показавшее убедительное превосходство предложенных алгоритмов.

Статья [6] 2016 года посвящена разработке информационной технологии раннего распознавания видов сельскохозяйственных культур по набору космических снимков MODIS на территориях масштаба региона. Раннее распознавание проводится в первой половине посевного сезона и характеризуется нехваткой наземных и космических данных для настройки алгоритмов распознавания. Предложено двухэтапное решение проблемы. На первом этапе по данным за прошедшие годы формируются модели и базы данных временных рядов сельскохозяйственных культур и агросезонов, на втором - добавляются данные текущего года для детектирования начального состояния (агросезона) для культур-объектов мониторинга и генерируется обучающая выборка на весь текущий сезон на основе построенных моделей и БД. В статье [7] 2016 года дан сравнительный анализ алгоритмов распознавания объектов лесного покрова и некоторых других природно-техногенных объектов на гиперспектральных аэрокосмических изображениях. Например, в одной из задач - семь основных классов: водная поверхность; дорожное покрытие; почвогрунты; луговая растительность; сосна; береза; осина. Для лесного покрова исследовался породный состав и возраст. Спектральная размерность задачи методом главных компонент ограничена четырьмя главными компонентами. Каждый класс далее охарактеризован опорным образцом и параметрами гауссовского распределения. Наилучшим из методов-участников оказался байесовский классификатор (БК) на основе гауссовских смесей, наихудшим - метрический классификатор. Метод К-взвешенных соседей показал точность соизмеримую с точностью нелинейных оптимальных классификаторов и может наравне с ними использоваться для задач распознавания лесного покрова разного породного состава и возраста. Для построения эталона класса в рассмотренных задачах оказалось достаточно 4 главных компонент.

В работе [8] 2018 года рассматривается использование изображающих гиперспектрометров для точного земледелия в полевом эксперименте по определению индекса влажности почвы, покрытой растительностью. Показано, что индекс влажности в каждой точке гиперспектраль-

ного изображения, где присутствует зелень, определяется отношением $I_{0,9}$ к $I_{0,97}$, где $I_{0,9}$ – спектральная яркость на длине волны 0,9 мкм, а $I_{0,97}$ – на длине волны 0,97 мкм.

В публикации [9] 2018 года, ориентированной на использование мультиспектральных изображений высокого разрешения (1-5м), предложена и исследована информационная технология обработки данных ДЗЗ для оценки ареалов растений, основанная на вычислении локальных признаков. Базовыми этапами предлагаемой технологии являются: суперпиксельная сегментация – выделение связанных участков локальной однородности на многоканальном изображении, расчёт признаков сегментов, кластеризация сегментов, формирование оценок состава ареала растительности. Этапы расчёта признаков и суперпиксельной сегментации совмещены в один процесс, позволяющий получить и признаки, и разбиение на локально однородные участки за один проход по изображению, сократив вычислительную сложность алгоритма и трудоемкость формирования обучающей выборки оператором. В состав признаков включены: минимальное, максимальное значение яркости суперпикселей по каждому каналу, математическое ожидание яркости по каждому каналу, площадь суперпикселя и пр. В работе использованы данные наземных исследований по 4 элементарным классам растительности: 1) разреженная травянистая растительность; 2) низкотравная растительность; 3) высокая трава; 4) деревья и кустарники. Эти данные использованы для формирования параметров классов при синтезе модельных изображений, а также для обучения и классификации изображений ДЗЗ.

Публикация [10], также 2018 года, демонстрирует потенциал гиперспектральных и мультиспектральных данных для мониторинга и оценки земного покрова в масштабах субъекта федерации, и выдвигает на первый план разработку спектральной библиотеки для классов земного покрова с построением стандартизированной системы классификации.

В исследовании использован 1 гиперспектрометр (Hyperion) и 2 мультиспектрометра (ALI и OLI). Для всех трех изображений применены: 1) алгоритм k-ближайших соседей (KNN) в качестве метода классификации с учителем; 2) метод migrating means clustering (MMC) в качестве метода классификации без учителя. Обучающие данные собраны на основе полевых работ и поддержаны привязкой к топографическим картам. Первоначально выделены 27 подклассов и обучающие площадки для них, которые затем объединены в 8 классов: 1. Вода; 2. Растительность; 3. Поселения; 4. Водно-болотные угодья; 5. Голая земля; 6. Транспорт; 7. Голые скалы; 8. Песчаные дюны. Полевые измерения проведены на переносном спектро радиометре FieldSpec 3 ASD (диапазон: VNIR, visible, near-infrared, и SWIR, shortwave infrared, между 350 и 2500 нм; точность: 1 нм) и GPS (Trimble PRO XRS) с точностью привязки 1м. Выполнено по 7-8 измерений на каждый класс, в случайных пунктах 60 зон каждого изображения. Эксперимент по оценке точности классификации подтвердил ожидаемое, что классификация с учителем лучше, чем классификация без учителя для всех трех изображений (Hyperion, ALI и OLI), а гиперспектральные изображения информативнее, чем мультиспектральные. Главное, однако, что автоматическая классификация по собранным эталонным образцам оказалась достаточно результативной как для ГСИ, так и для МСИ.

Все рассмотренные публикации последних лет в итоге подтверждают актуальность работ по созданию баз данных эталонов объектов ГСИ и эталонов состояний этих объектов для потенциальных прикладных задач управления территориями, а также актуальность разработки методов анализа ГСИ, обеспечивающих разработку информационного наполнения эталонов. Это же относится и к мультиспектральным изображениям, которые легче, в силу большей доступности, использовать в практике управления территориями, но для них более часто приходится обращаться, наряду со спектральными, к текстурным признакам состояний объекта классификации.

3. Методы анализа и разметки объектов ГСИ

В обзоре отмечено, что предложенная Landgrebe [1] номинальная последовательность шагов по анализу ГСИ во многом сохраняет свою актуальность до настоящего времени. Это справедливо, однако есть в описанной схеме особенности, ведущие и к потере существенной информации ГСИ. Собственно применение PCA для существенного понижения размерности данных исходно предполагает потерю информации. Остается только вопрос о том, потерю

какой информации считать несущественной. Важно также, что результат применения PCA зависит от содержания конкретного изображения. В связи с этим мы и хотели бы уточнить применение метода главных компонент (PCA) в номинальной последовательности шагов по анализу ГСИ в случаях требующих «тонкого» анализа.

Рассмотрим первые два шага номинальной последовательности анализа ГСИ по Landgrebe. *Первым шагом* является «Разграничение классов и формирование образцов для обучения». Напомним, что классы по Landgrebe должны быть: исчерпывающими (определенными для каждого пикселя ГСИ); разделимыми; информационно ценными для пользователя. Рекомендуется по возможности выстраивать набор классов разделимый по спектральным признакам. На этом шаге должно быть предварительно определено число классов и выбраны образцы для обучения по каждому из классов. Процесс анализа всегда начинается с визуального обзора ГСИ. При этом обычно используется 3-цветное окрашивание видимого и инфракрасного диапазонов или каких-то других сочетаний каналов, которые для предварительной визуальной классификации полезно разделить цветом. Эта операция полезна в любых случаях и задачах и конечно должна присутствовать как обязательный инструмент анализа ГСИ. Точно также стоит приветствовать стремление максимальным образом обеспечить спектральную разделимость классов, которую мы сможем проконтролировать по спектральной разделимости размеченных образцов классов.

Второй шаг: «Извлечение признаков и предварительная классификация». На этом шаге предполагается значительно понизить размерность пространства ГСИ, применив метод главных компонент или аналогичный по возможностям метод и выбрав количество главных компонент (m), соответствующее заданной точности. После этого можно убедиться, что образцы классов разделимы в пространстве m главных компонент с точки зрения линейного дискриминантного анализа (ЛДА). Это можно проконтролировать и визуально, наблюдая кластеры признаков размеченных образцов на координатных плоскостях базиса главных компонент. При неразделимости каких-либо классов в базис вводятся дополнительные компоненты. Проверка того, является ли список классов достаточно исчерпывающим, проводится проверкой наличия пикселей, не отнесенных ни к одному из классов. В случае наличия таковых, неклассифицированные пиксели доразмечаются метками имеющихся классов, к которым они должны относиться, или метками дополнительных классов. Пример разметки средствами анализа ГСИ, входящими в ГИС Terra Плюс [11], показан на рисунке 1.

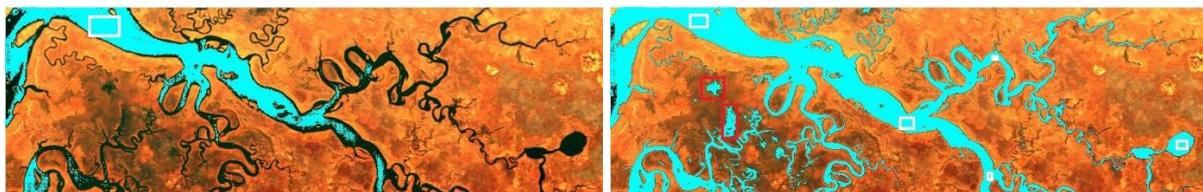


Рисунок 1. Выбор 1 образца (1440 пикселей, окно с белой рамкой) для разметки реки на ГСИ и площадь реки (24935 пикселей) автоматически закрасенная голубым цветом в ответ на этот выбор; выбор 5 образцов (4191 пиксель), обеспечивший полную закраску основного русла, всех притоков и озер (95935 пикселей). В обоих случаях построен только один распознающий базис. Примеры зон избыточной маркировки (заболоченные места) помечены красными рамками.

Источником данных для рисунка 1 является ГСИ Suwannee_0609-1331_ref.dat: водно-болотные угодья бассейна реки Suwannee в штате Флорида США, спектрометр Spectir, число каналов $n=360$.

Работоспособность процедуры второго шага многократно проверена практикой. Однако, мы считаем нужным внести в нее некоторую детализацию. Во-первых, мы настаиваем на полном сохранении эталонных сигнатур пикселей ГСИ, независимо от числа каналов, оказавшихся необходимыми для текущей классификации в конкретной прикладной задаче (может быть за исключением полностью зашумленных каналов). Это позволит выстраивать классификацию, не как зависящую от условий конкретной задачи и конкретного ГСИ, а как многократно

используемую и подкрепленную эталонными (опорными) сигнатурами, которые подтверждены в полевых испытаниях, как в [3], [4], [6-10].

3.1. Роль сигнатур, их линейной зависимости и величин среднеквадратических отклонений в процедуре классификации

В [10] показан пример классификации 27 подклассов 8 разнородных классов, демонстрирующий подобие сигнатур всех 27 подклассов в диапазоне 82-96 каналов спектрометра Nuregion. Это на практическом материале говорит о важности детектирования факта линейной зависимости между сигнатурами и использовании масштабного коэффициента этой зависимости как признака класса и подкласса. В нашей практике присутствие линейной зависимости сигнатур классов является регулярным. На рисунке 2 показан пример таких сигнатур для точек произвольно выбранных на области реки и на области суши в ГСИ Suwannee_0609-1331_ref.dat (см. также рисунок 1).

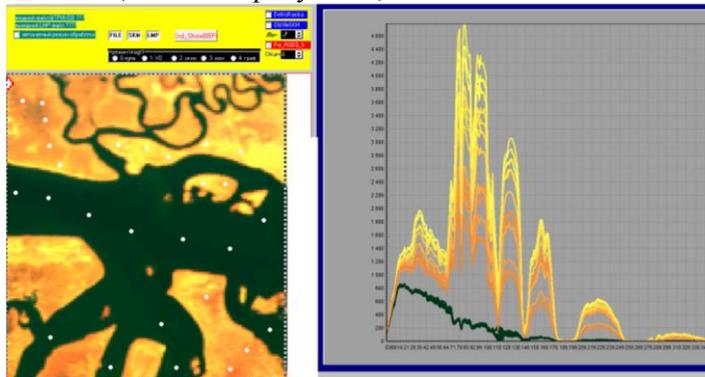


Рисунок 2. 28 пикселей ГСИ Suwannee для различных участков реки и суши (слева, белые точки) и их сигнатуры, демонстрирующие линейную зависимость внутри класса (цвет кривой графика соответствует цвету помеченного пикселя на исходном изображении).

В качестве детектора линейной зависимости между векторами сигнатур \mathbf{x} и \mathbf{y} двух пикселей ГСИ, с числом каналов n , можно использовать как ковариацию (1),

$$\text{cov}(\mathbf{x}, \mathbf{y}) = E[(\mathbf{x} - E\mathbf{x})(\mathbf{y} - E\mathbf{y})], \quad (1)$$

так и коэффициент корреляции Пирсона (2)

$$r(\mathbf{x}, \mathbf{y}) = \text{cov}(\mathbf{x}, \mathbf{y}) / (\sigma_{\mathbf{x}} \cdot \sigma_{\mathbf{y}}) = \text{cov}(\mathbf{x}, \mathbf{y}) / (\sqrt{D_{\mathbf{x}}} \cdot \sqrt{D_{\mathbf{y}}}), \quad (2)$$

где E – момент первого порядка; D – дисперсия; σ – среднеквадратическое отклонение.

Для детектирования линейной зависимости с эталонными сигнатурами нам необходимы несмещенные величины сигнатур текущего ГСИ, поэтому полагаем в (1) $E\mathbf{x} = E\mathbf{y} = 0$, после чего имеем:

$$\text{cov}(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y}) / n; \quad r(\mathbf{x}, \mathbf{y}) = (\mathbf{x} \cdot \mathbf{y}) / (|\mathbf{x}| \cdot |\mathbf{y}|), \quad (3)$$

где $|\mathbf{x}|$ и $|\mathbf{y}|$ – модули векторов \mathbf{x} и \mathbf{y} .

Коэффициент корреляции Пирсона превращается в нормированное скалярное произведение векторов сигнатур и представляется нам более интересным детектором, т.к. $\arccos(r)$ мы можем использовать как меру углового отклонения сигнатуры \mathbf{x} от сигнатуры \mathbf{y} . Сами же величины среднеквадратических отклонений $\sigma_{\mathbf{x}}, \sigma_{\mathbf{y}}$ (4)

$$\sigma_{\mathbf{x}} = \sqrt{D_{\mathbf{x}}} = \sqrt{E[(\mathbf{x} - E\mathbf{x})^2]}, \quad (4)$$

их отношения или квантованные значения будем использовать как признак класса (подкласса).

При таком подходе опорой классификации становится не результат метода главных компонент (РСА), как в варианте Landgrebe, который зависит от содержания конкретного гиперспектрального изображения, а эталонная сигнатура класса (или временной ряд эталонов). Таким образом, процедура детектирования линейной зависимости сигнатур по коэффициенту корреляции Пирсона становится необходимой процедурой второго шага, применяемой до РСА.

В той же мере она необходима и на первом шаге номинальной последовательности по Landgrebe.

3.2. Роль метода главных компонент в процедуре классификации

Однако метод PCA от этого не теряет своей значимости как эффективный аппарат анализа ГСИ. Мы считаем необходимым применять его к локальной однородной выборке, определяющей локальный эталон класса объекта на области выборки. Если однородность выборки обеспечивает специалист, то мы можем положить локальный эталон класса равным средней по выборке сигнатуре, что соответствует процедуре PCA. В качестве локального эталона может быть использован также готовый эталон. Далее процедура PCA обеспечивает ортогональность и статистическую независимость по компонентам разложения. Это выражается в диагональности матрицы ковариации, в результате чего выражение расстояния Махаланобиса между двумя сигнатурами приобретает вид (5):

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2 / \sigma_i^2}, \quad (5)$$

где σ_i - среднее квадратическое отклонение x_i от y_i в выборке, d - нормализованное расстояние Евклида. В результате каждая из главных компонент получает в величине σ_i свой масштаб для решения задачи линейного дискриминантного анализа (ЛДА).

Главной задачей применения метода главных компонент на однородной выборке является на наш взгляд «тонкий» анализ – выявление подклассов локальной классификации, имеющих прикладной смысл. Для наглядности оценки прикладной ценности выделенных подклассов целесообразно использовать стандартные приемы: 1) визуализация подклассов различным цветом и яркостью; 2) визуализация проекций сигнатур выборки на координатные плоскости главных компонент для оценки их кластеризации и возможности ЛДА (рисунок 3).

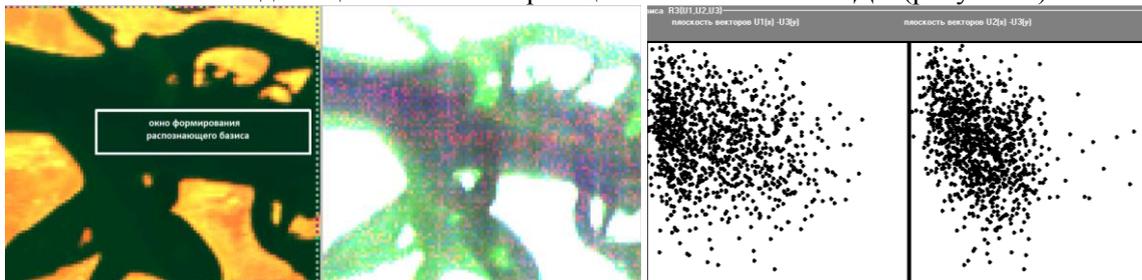


Рисунок 3. Цвето-яркостная иллюстрация дискриминантных свойств трехкомпонентного базиса, построенного методом PCA (середина) по выборке пикселей реки окном, показанным слева. Темная область цвето-яркостной иллюстрации соответствует сигнатуре локального класса и более глубокой части реки, зеленая – подклассу мелководной части реки. Проекции 1155 пикселей выборки на 2 плоскости базиса (справа).

В зависимости от степени однородности выборки PCA может дать разные результаты. На рисунке 3 дан пример анализа ГСИ Suwannee_0609-1331_ref.dat, представляющий достаточно частую ситуацию при выборе совершенно однородного на вид участка (прямоугольник на левом изображении). Темная область цвето-яркостной иллюстрации (на втором слева изображении) соответствует сигнатуре локального класса и более глубокой части реки, зеленая – подклассу мелководной части реки, голубая – самая мелководная часть; красная – шумовая составляющая. Проекции 1155 пикселей выборки на 2 плоскости базиса (справа) представлены на двух изображениях справа и, по зрительному впечатлению неразделимы методом ЛДА до применения PCA. Мы можем также столкнуться со случаем когда PCA на однородной выборке может дать и только шумовые компоненты, что вместе с оценкой их среднее квадратических отклонений также весьма полезно в определении пороговых значений для ошибки классификации.

На рисунках 4-5 представлен пример анализа фрагмента водной поверхности залива Сан-Франциско на ГСИ Moffett Field. Этот залив известен как первый заказник водно-болотных

угодий внутри городской территории США (Don Edwards San Francisco Bay National Wildlife Refuge). Для него характерно большое разнообразие классов и подклассов водно-болотных территорий, посещаемое 280 видами птиц. В частности на рисунке 4 для исследования выделен фрагмент неоднородного приливного загрязнения. По данному образцу выделены водные территории, относящиеся к заданному фрагментом классу.



Рисунок 4. ГСИ Moffett Field с автоматической классификацией по окну обучения (показано белой рамкой в левой части изображения).

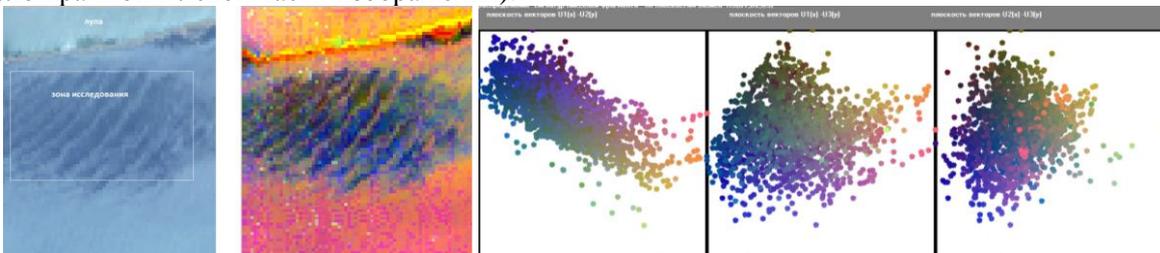


Рисунок 5. Фрагмент залива с окном выбора (слева, белая рамка); визуализация различным цветом ортогональных компонентов базиса классификации, построенного методом PCA, (загрязнению соответствуют синий и зеленый цвета, свободной воде залива – красный, дорога по дамбе, разделяющей залив и солевое озеро выше дороги, - желтый). В правой части показаны проекции пикселей окна выбора на 3 координатных плоскости главных компонент: заметны кластеры классификации, достаточно отчетливо разделяемые цветом.

На рисунке 5 (слева) выбранный фрагмент и окрестная зона интереса показаны с увеличением для повышения точности выбора (инструмент Лупа). Правее показано цветное воспроизведение результата метода главных компонент для 3 главных компонент. Основной массе загрязнения соответствуют синий (середина) и зеленый (края) цвета. Открытой воде соответствует красный цвет (небольшая часть пикселей в окне выбора). В правой части показаны проекции 2030 пикселей окна выбора на 3 координатных плоскости главных компонент: заметны кластеры классификации, достаточно отчетливо разделяемые цветом.

4. Обсуждение результатов

Извлечение признаков является одной из наиболее важных операций в классификации гиперспектральных изображений. Это всегда необходимо сделать перед классификацией и лучше всего на основе анализа классифицируемого гиперспектрального изображения. В случае использования эталонов из базы данных, или при наработке таких эталонов на исследуемом ГСИ, первым необходимым шагом анализа является процедура детектирования линейной зависимости сигнатур по величине коэффициента корреляции Пирсона (см. рисунок 2). Эта процедура является адекватным средством и для кластерного анализа ГСИ по критерию углового отклонения сигнатур уже на первом шаге номинальной последовательности анализа ГСИ.

На втором шаге процедура детектирования линейной зависимости сигнатур предшествует применению тонкого анализа однородной выборки средствами PCA. В показанных выше экспериментах метод главных компонент (PCA) использован в качестве метода исследования существования подклассов в классах объектов ГСИ, определяемых выборками однородных

фрагментов изображений. Применение PCA совместно с визуальной и количественной оценкой получившихся главных компонент позволяет увидеть имеют ли построенные главные компоненты реальную прикладную ценность или они отражают шумовую составляющую изображения, как на рисунках 3 и 5.

Компоненты с небольшими среднеквадратическими отклонениями могут иметь полезную информацию, как для различения классов в процессе классификации, так и для детектирования различных состояний объекта одного класса в пространстве и времени, что может сделать значимыми даже самые небольшие величины среднеквадратических отклонений.

5. Заключение

В работе обсуждается начавшееся развитие методов распознавания объектов гиперспектральных изображений (ГСИ) в направлении создания и использования банков эталонных сигнатур для объектов прикладных задач мониторинга окружающей среды, а также, необходимая в этих условиях, модификация номинальной последовательности шагов по анализу ГСИ, предложенной Landgrebe. Подход основан на рассмотрении пикселя ГСИ как сигнатуры, хранящей все спектральные признаки как объекта и его состояния, а ГСИ в целом - как двумерного поля сигнатур. В качестве первого шага анализа предлагается процедура детектирования линейной зависимости сигнатур по величине коэффициента корреляции Пирсона. Основным аппаратом анализа также, как и по Landgrebe, остается метод главных компонент, но он используется уже не для построения классов, а для исследования наличия в классе подклассов существенных для прикладной области. Подход иллюстрирован инструментальными средствами анализа для исследования однородных фрагментов объектов гиперспектральных изображений, включенными в состав ГИС Terra Plus [11]. Экспериментальный материал включает такие объекты как: вода, болота, грунт, растительность, бетон, загрязнения. Выделение образцов объекта на изображении производится интерактивно пользователем. Из исследованных образцов объектов гиперспектральных изображений в ГИС Terra Plus формируется база эталонов для классов (подклассов) объектов, которая, в свою очередь, может использоваться для автоматизации разметки ГСИ с целью применения методов машинного обучения для распознавания объектов ГСИ и их состояний.

6. Литература

- [1] Landgrebe, D. Information Extraction Principles and Methods for Multispectral and Hyperspectral Image Data / D. Landgrebe // Information Processing for Remote Sensing. – NJ: World Scientific Publishing Company, 1999. – P. 3-38. DOI: 10.1142/3999.
- [2] Pakhomov, P.A. Investigation of hyperspectral image pixel signatures by the empirical mode decomposition method / P.A. Pakhomov, A.V. Borusyak, V.E. Turlapov // CEUR Workshop Proceedings. – 2018. – Vol. 2210. – P. 352-364.
- [3] Раменская, Е.В. Получение опорных спектральных сигнатур при гиперспектральной съемке / Е.В. Раменская, А.О. Гурьянова, А.Г. Мандра, В.В. Ермаков // Экология и промышленность России. – 2014. – Т. 10. – С. 44-47. DOI: 10.18412/1816-0395-2014-10-44-47.
- [4] Раменская, Е.В. Классификация гиперспектральных изображений с использованием кластерной структуры данных / Е.В. Раменская, М.П. Кузнецов, В.В. Ермаков, О.Р. Баркова, А.А. Бран // Современные проблемы дистанционного зондирования Земли из космоса. – 2017. – Т. 14, № 7. – С. 9-19. DOI: 10.21046/2070-7401-2017-14-7-9-19.
- [5] Денисова, А.Ю. Обнаружение аномалий на гиперспектральных изображениях / А.Ю. Денисова, В.В. Мясников // Компьютерная оптика. – 2014. – Т. 38, № 2. – С. 287-296.
- [6] Воробьева, Н.С. Информационная технология раннего распознавания видов сельскохозяйственных культур по космическим снимкам / Н.С. Воробьева, В.В. Сергеев, А.В. Чернов // Компьютерная оптика. – 2016. – Т. 40, № 6. – С. 929-938. DOI: 10.18287/2412-6179-2016-40-6-929-938.

- [7] Козодеров, В.В. Сравнительный анализ алгоритмов распознавания объектов лесного покрова на гиперспектральных аэрокосмических изображениях / В.В. Козодеров, Т.В. Кондранин, Е.В. Дмитриев // Исследование земли из космоса. – 2016. – Т. 6. – С. 45-55. DOI: 10.7868/S020596141606004X.
- [8] Подлипов, В.В. Экспериментальное определение влажности почвы по гиперспектральным изображениям / В.В. Подлипов, В.Н. Щедрин, А.Н. Бабичев, С.М. Васильев, В.А. Бланк // Компьютерная оптика. – 2018. – Т. 42, № 5. – С. 877-884. DOI: 10.18287/2412-6179-2017-42-5-877-884.
- [9] Варламова, А.А. Информационная технология обработки данных ДЗЗ для оценки ареалов растений / А.А. Варламова, А.Ю. Денисова, В.В. Сергеев // Компьютерная оптика. – 2018. – Т. 42, № 5. – С. 864-876. DOI: 10.18287/2412-6179-2018-42-5-864-876.
- [10] Boori, M.S. Comparison of hyperspectral and multi-spectral imagery to building a spectral library and land cover classification performance / M.S. Boori, R. Paringer, K. Choudhary, A. Kupriyanov // Computer Optics. – 2018. – Vol. 42(6). – P. 1035-1045. DOI: 10.18287/2412-6179-2018-42-6-1035-1045.
- [11] Лебедев, Л.И. Комплексный анализ и мониторинг состояния окружающей среды на основе данных ДЗЗ / Л.И. Лебедев, Ю.В. Ясаков, Т.Ш. Утешева, В.П. Громов, А.В. Борусьяк, В.Е. Турлапов // Компьютерная оптика. – 2019. – Т. 43 (в печати).

Благодарности

Работа выполнена при поддержке гранта РФФИ № 16-11-00068.

Analysis and object markup of hyperspectral images for machine learning methods

V.P. Gromov¹, L.I. Lebedev¹, V.E. Turlapov¹

¹National Research State University named after N.I. Lobachevsky, Gagarin ave. 23, Nizhny Novgorod, Russia, 603952

Abstract. The modification of the nominal sequence of steps for analyzing the HSE proposed by Landgrebe, which is necessary for the context of the appearance of libraries of reference signatures for environmental monitoring, is discussed. The approach is based on considering the HSI pixel as a signature that stores all spectral features of an object and its states, and the HSI as a whole - as a two-dimensional signature field. As a first step of the analysis, a procedure is proposed for detecting a linear dependence of signatures by the magnitude of the Pearson correlation coefficient. The main apparatus of analysis, as in Landgrebe, is the method of principal component analysis, but it is no longer used to build classes, but to investigate the presence in the class of subclasses essential for the applied area. The experimental material includes such objects as water, swamps, soil, vegetation, concrete, pollution. Selection of object samples on the image is made by the user. From the studied images of HSI objects, a base of reference signatures for classes (subclasses) of objects is formed, which in turn can be used to automate HSI markup with the aim of applying machine learning methods to recognize HSI objects and their states.