

Пространственный анализ гиперспектральных изображений

Л.И. Лебедев¹, А.О. Шахлан²

lebedev@pmk.unn.ru|amega123@mail.ru

¹ННГУ им. Н.И. Лобачевского, ул. Ульянова, 10, Нижний Новгород, 603005, Россия;

²МГТУ им. Н.Э. Баумана, 2-я Бауманская ул., д.5, стр.1, Москва, 105005, Россия

В работе предлагаются методы и технология пространственного анализа гиперспектральных изображений. Сжатие, распознавание и кластерный анализ гиперспектральных изображений основаны на получении подпространств, с требуемыми для решения этих задач характеристиками. Сжатое описание изображений и решающие правила классификации базируются на информативных признаках. Методами прослеживания контуров формируется описание границ кластеров и классов на изображении. Предлагаемые методы и технология анализа демонстрируются на гиперспектральном изображении Deepwater Horizon Oil Spill спектрометра Spectir.

Ключевые слова: гиперспектральное изображение, сжатие, распознавание, кластерный анализ, подпространство, собственные вектора, обучающие последовательности, информативные признаки, контур.

Spatial analysis of hyperspectral images

L.I. Lebedev¹, A.O. Shakhlan²

lebedev@pmk.unn.ru|amega123@mail.ru

¹ Lobachevsky State University of Nizhny Novgorod, ul Ul'janova, 10, Nizhny Novgorod, 603005, Russia;

² Bauman Moscow State Technical University, 2-ya Baumanskaja ul., d.5, str.1, Moscow, 105005, Russia

In the paper, methods and technology of spatial analysis of hyperspectral images are proposed. Compression, recognition and cluster analysis of hyperspectral images are based on obtaining subspaces, with the characteristics required for solving these problems. The compressed description of images and the decisive rules of classification are based on informative signs. The methods of tracing outlines form a description of the boundaries of clusters and classes in the image. The proposed methods and analysis technology is demonstrated on the hyperspectral image «Deepwater Horizon Oil Spill» obtained by the Spectir spectrometer.

Keywords: hyperspectral image, compression, recognition, cluster analysis, subspace, eigenvectors, training sequences, informative feature, contour.

1. Введение

На протяжении двух десятилетий ведутся исследования использования снимков высокого спектрального разрешения для решения различных задач в области разведки земных ресурсов, состояния окружающей среды, мониторинга различного рода рисков. Области использования гиперспектральных изображений (ГСИ) обширны. Анализ гиперспектральных снимков стал одним из самых эффективным и актуальным применением решения задач дистанционного зондирования. Сегодня гиперспектральные снимки, в отличие от других ДДЗ (дистанционное зондирование Земли), позволяют извлекать более точную и детальную информацию. Результаты обработки гиперспектральных данных ДЗЗ находят все большее применение в агропромышленном комплексе, геологической разведке, экологическом мониторинге, что подтверждается возрастающим количеством публикаций по анализу ГИ в этих тематических областях [2,6-8].

Основными направлениями в анализе ГИ по праву считаются задачи сжатия (фильтрации) изображений, распознавания (идентификации) объектов на снимках, вопросы кластерного анализа и получения (уточнения) границ областей интереса. Решение этих задач нашло отражение в работах и докладах IV международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ-2018). В данной работе задачи сжатия, распознавания, кластеризации и выделения границ объектов предлагается осуществлять на основе получения и анализа соответствующих подпространств с использованием единой технологии [5], получившей дальнейшее развитие.

Пусть гиперспектральное изображение задано моделью, в которой каждый пиксель описывается набором

признаков, значения которых соответствуют интенсивностям отражения при различных частотах одного и того же исследуемого элементарного фрагмента. В этом контексте, описание пикселя с одной стороны соответствует амплитудно-фазовому представлению, как это отображено на рис. 1, а с другой стороны является точкой в линейном пространстве R_n , $x \in R_n$. Если в прямоугольной таблице в ячейках по строкам теперь записать значения интенсивностей пикселя, то в итоге получим классическую таблицу «объект - свойство» (ТОС) T_{nM} , свойственную для задач распознавания образов, в которой параметром M задано количество пикселей.

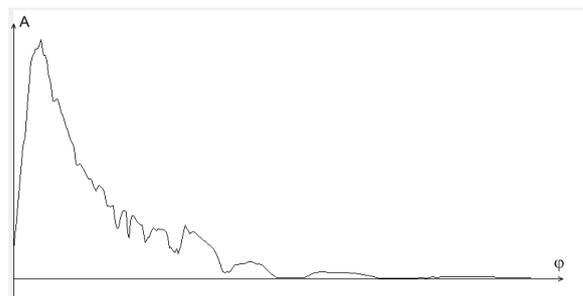


Рис.1. Амплитудно-частотное представление пикселя

2. Методы анализа

Пусть в пространстве R_n задано подпространство R_m , определяемое базисом $U = (u^1, u^2, \dots, u^m)$. Тогда любая точка $x \in R_m$ может быть представлена своими

коэффициентами свертков $c_j = x^T \cdot u^j$, $j = 1, 2, \dots, m$,

причем, $x = \sum_{j=1}^m c_j \cdot u^j$. Отсюда,

$$\begin{aligned} x_k &= \sum_{j=1}^m c_j \cdot u_k^j = \sum_{j=1}^m \left(\sum_{i=1}^n x_i \cdot u_i^j \right) \cdot u_k^j = \\ &= \sum_{i=1}^n x_i \cdot \left(\sum_{j=1}^m u_k^j \cdot u_i^j \right) = \sum_{i=1}^n x_i \cdot \gamma_i^k = x^T \cdot \gamma^k. \end{aligned} \quad (1)$$

Имеем, $\Gamma = (\gamma^1, \gamma^2, \dots, \gamma^m)$. В матричном виде $\Gamma = U \cdot U^T$. Среди $(\gamma^1, \gamma^2, \dots, \gamma^m)$ линейно независимых точно равно m . Действительно, строки матрицы U можно рассматривать как коэффициенты разложения векторов Γ в базисе U , ранг матрицы которого равен m . Пусть это вектора $G = (g^1, g^2, \dots, g^m)$. Пусть номера линейно-независимых строк матрицы U будут v_1, v_2, \dots, v_m , тогда $g^j = \gamma^{v_j}$, $j = 1, 2, \dots, m$. Отсюда, в матричном представлении $G = U \cdot V^T$, где V , матрица составленная из линейно-независимых строк матрицы U . Пусть компоненты матрицы $K = (k^1, k^2, \dots, k^m)$ являются коэффициентами разложения векторов из Γ по базису G , то есть $\Gamma = K \cdot G^T$. Отсюда, $U \cdot U^T = K \cdot V \cdot U^T$, и $K = U \cdot V^{-1}$. Из (1) следует

$$\begin{aligned} x &= (x_1, x_2, \dots, x_n)^T = (x^T \cdot \gamma^1, x^T \cdot \gamma^2, \dots, x^T \cdot \gamma^m)^T = \\ &= \left(\sum_{j=1}^m k_1^j \cdot (x^T \cdot \gamma^{v_j}), \sum_{j=1}^m k_2^j \cdot (x^T \cdot \gamma^{v_j}), \dots, \sum_{j=1}^m k_m^j \cdot (x^T \cdot \gamma^{v_j}) \right). \end{aligned}$$

Окончательно, $x = \sum_{j=1}^m x_{v_j} \cdot k^j$, где x_{v_j} , $j = 1, 2, \dots, m$

линейно-независимые признаки. Если точка $x \notin R_m$, то в целях согласования с коэффициентами свертков для ее восстановления надо брать сглаженные признаки $y_j^* = x_{v_j}^* = x^T \cdot g^j$. Тогда по значениям коэффициентов

сверток $c^T = (c_1, c_2, \dots, c_m)$ однозначно можно получить набор информативных признаков $(y^*)^T = (y_1^*, y_2^*, \dots, y_m^*)$

и наоборот: $c = V^{-1} \cdot y^*$, $y^* = V \cdot c$.

3. Получение подпространств.

В предлагаемых методах сжатия, распознавания и кластеризации базис подпространства формируются на основе собственных векторов, соответствующих наибольшему собственным значениям матрицы D специального вида:

$$D = \sum_{x \in X} \sum_{y \in Y} \frac{(x-y) \cdot (x-y)^T}{\|x-y\|^\beta}, \quad (2)$$

где X и Y - обучающие последовательности.

При сжатии ГИ в качестве множества X первоначально берутся все пиксели изображения, а множество Y представляет либо нулевая точка, либо средняя точка \bar{x} , полученная по всем пикселям ГИ. Значение β устанавливается равным нулю. Количество

векторов m , базиса подпространства R_m берется с тем расчетом, чтобы отношение разброса по первому вектору к разбросу по m -ному направлению удовлетворяло заданному порогу, то есть $\sqrt{\lambda_1/\lambda_m} > Thr$. Количество взятых векторов базиса U обеспечивает не только уровень среднеквадратической ошибки и качество аппроксимации пикселей, но и определяет набор информативных признаков нового описания пикселей и коэффициент сжатия k_r . В случае линейного подпространства R_m , когда $Y = \{0\}$, коэффициент сжатия тогда равен $k_r = n \cdot M / [m \cdot (M + n)]$, а случае линейного многообразия $M = \bar{x} + R_m$, когда $Y = \{\bar{x}\}$, его значение равно $k_r = n \cdot M / [m \cdot (M + n + 1)]$. Отметим, что значения информативных признаков $(x_{v_1}, x_{v_2}, \dots, x_{v_m})$ остаются в том же диапазоне, что и для исходного набора и поэтому, их кодировка не приводит к увеличению разрядности при передаче, что может нарушаться при кодировании интегральными признаками (c_1, c_2, \dots, c_m) . Для дальнейшего обеспечения качества аппроксимации требуется формирование новой обучающей последовательности X^1 . Использование других полученных собственных векторов нецелесообразно, так как они аппроксимируют случайные данные. Новая последовательность должна формироваться на основе пикселей не удовлетворяющих качеству аппроксимации. Формирование может осуществляться при использовании различных критериев (Евклидова метрика, метрика Чебышёва и т.д.) на базе ошибок аппроксимации точек множества X . Далее аналогичным образом для множества X^1 находится базис и определяется дополнительный набор информативных признаков, который включается в общий список. Эта итеративная процедура завешается при выполнении критерия качества аппроксимации. Следует отметить, что алгоритмом сжатия предусмотрена смешанная аппроксимация пикселей как наборами $(x_{v_1}^*, x_{v_2}^*, \dots, x_{v_m}^*)$, так и $(x_{v_1}, x_{v_2}, \dots, x_{v_m})$ в зависимости от полученного качества их восстановления.

При распознавании значение β берется положительным, чтобы обеспечить подавление наиболее удаленных точек обучающих множеств при построении ковариационной матрицы межклассового разброса и, наоборот, увеличить вклад ближайших точек, от разделения которых в основном зависит качество распознавания. Это позволяет получить лучший, в плане построения решающих правил, базис разделяющего подпространства множеств. При решении практических задач распознавания объектов на гиперспектральных изображениях задание обучающих последовательностей может сводиться к заданию соответствующих фрагментов. В этих ситуациях после верификации всех пикселей фрагментов все оставшееся множество точек разбивается на два подмножества X и Y , которые не должны содержать пиксели одноименных классов. В случае задания фрагмента только для одного класса (множество X) множество Y формируется на основе всех пикселей изображения, не имеющих в описании сходства с точками распознаваемого класса, которое можно установить корреляционно-экстремальными контурными методами [4].

При решении задач кластерного анализа из тех же соображений берется значение $\beta < 0$. Здесь все множество пикселей изображения разбиваются на два подмножества X и Y произвольным образом.

Построение решающих правил осуществляется в подпространстве R_2 , собственных векторов, соответствующих наибольшим собственным значениям. Используется иерархическая структура классификатора. На каждом уровне формируются новые обучающие последовательности из точек зоны отказов предыдущего уровня.

Построение классификатора осуществляется на базе информативных признаков. Для этого используются только кусочно-линейные решающие правила. Если решающее правило задано в виде $F(z) = u^T \cdot z - d = 0$, $\|u\| = 1$, то информативные признаки поэтапно выбираются в порядке убывания $|u_{V_j}|$, $j = 1, 2, \dots, m$. При этом на каждом шаге

решающее правило будет иметь вид $F(\hat{z}) = \hat{u}^T \cdot \hat{z} - \hat{d} = 0$, где $\hat{u} = (u_{V_1}, u_{V_2}, \dots, u_{V_{m-1}}, \Phi_{m-1}/u_{V_m})$, а

$$\Phi_{m-1} = 1 - \sum_{j=1}^{m-1} (u_{V_j})^2.$$

Для получения границ кластеров или распознанных объектов строится матрица с полутоновым описанием ячеек, размеры которой совпадают с исходным снимком. Всем пикселям изображения, удовлетворяющим условию принадлежности данному классу или кластеру, в соответствующие ячейки матрицы заносится идентификационный код. Далее методами прослеживания контуров формируется их описание [1,3].

4. Экспериментальные исследования

В качестве исходного изображения возьмем ГСИ Deepwater Horizon Oil Spill, полученное с использованием спектрометра Spectir.. Данное ГСИ содержит 371200 пикселей (матрица из 320 столбцов и 1160 строк), размерностью $n = 360$ каждый (число частот - каналов в спектрометре). Амплитуда сигнала колеблется в диапазоне от 1 до 32766 и была описана целой двухбайтовой переменной. Общий объем файла составил 267264000 байт. В связи с большим количеством пикселей (сотни тысяч), высокой размерностью их описания (сотни признаков) и большой вариабельностью значений по каждой частоте (десятки тысяч) алгоритмы и программы были ориентированы на использование 64-разрядных переменных целого типа и 80-разрядных переменных действительного типа, что естественно отразилось на их быстродействии.

Для сжатия ГСИ были построены за один проход две матрицы D при $Y = \{0\}$ и $Y = \{\bar{x}\}$ и найдены их собственные вектора. В результате анализа (автоматического, на основании отношений собственных значений) был в качестве базовой аппроксимации взят вариант с использованием линейного многообразия на основе пяти собственных векторов ($\lambda_1/\lambda_5 = 270$). Далее были определены номера пяти линейно-независимых признаков (каналов): 120, 13, 131, 101, 48. Таким образом, сжатое базовое описание определяется средней точкой \bar{x} и набором признаков $(x_{120}^*, x_{13}^*, x_{131}^*, x_{101}^*, x_{48}^*)$. Это вариант сжатия набора пикселей с использованием координатного среднеквадратического критерия по ансамблю точек. В нашем случае полученный набор признаков не смог обеспечить необходимое качество аппроксимации всех пикселей, которое оценивалось на основе среднеквадратической ошибки (СКО). На основе пикселей, у которых СКО превышало пороговую величину

было сформировано новое множество. Описаниями точек этого множества E служили ошибки аппроксимации соответствующих пикселей. На рис.2 отображен этот набор пикселей, из которого видно разбиение этого множества на кластеры, для которых получение контурной модели представления является достаточно простой задачей.



Рис.2. Выделение кластеров ГСИ

Аналогичным образом по множеству E была найдена ковариационная матрица и получены ее собственные вектора. В результате был получен набор из 5 признаков для аппроксимации точек из E : 120, 6, 12, 88, 132. В итоге,

стала возможным аппроксимация с хорошим качеством даже «возмущенных» пикселей, представленных на рис. 3.

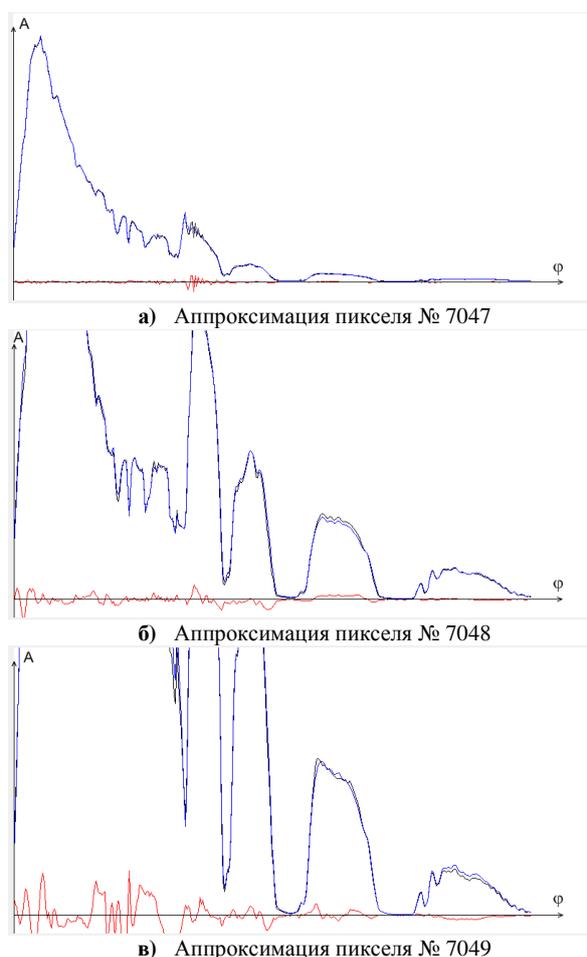


Рис.3. Динамика изменения характеристик пикселей ГСИ

Неудовлетворительная аппроксимация ошибок этого уровня была получена у 779 пикселей. Так как передача напрямую 779 ошибок будет по объему занимать меньше байт, чем введение в список информативных даже одного нового признака, то процедура сжатия бала завершена на этом этапе. Коэффициент сжатия составил более 33.

Методами построения простых решающих правил [5] с учетом специфики данных была решена задача распознавания помеченных выше 779 пикселей. Классификатор для выделения точек данного класса был построен на трех информативных признаках.

5. Заключение

Полученный результат применения предложенных методов сжатия, распознавания и кластеризации показал эффективность описанной технологии анализа ГСИ. Характерной чертой этих методов является возможность управляемого воздействия на решение задач анализа ГСИ (в том числе и интерактивного). Наибольшая трудность этой технологии заключена во временной сложности построения автокорреляционных матриц при распознавании и кластеризации ГСИ.

6. Благодарности

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

7. Литература

- [1] Васин, Ю.Г. Математические модели структурированного описания графических изображений./Ю.Г. Васин, О.А. Башкиров, С.Б. Рудометова//Межвузовский тематический сборник научных трудов «Автоматизация обработки сложной графической информации. – Изд-во ГГУ, Горький, 1984. – С. 92-117.
- [2] Гашников, М.В. Иерархическая сеточная интерполяция при сжатии гиперспектральных изображений./ М.В. Гашников, Н.И. Глумов // Компьютерная оптика. – 2014. – Т. 38, – № 1. – С. 87-93.
- [3] Дуда, Р. Распознавание образов и анализ сцен./ Р. Дуда, П. Харт// М.: Издательство «Мир». – 1976. – 512 с.
- [4] Лебедев, Л.И. Корреляционно экстремальные контурные методы распознавания. Теоретические основы: Учебное пособие./ Л.И. Лебедев// Изд-во Нижегородского государственного университета, Нижний Новгород - 2013. -113с. - ISBN 978-5-91326-308-7.
- [5] Лебедев, Л.И. Простые решающие правила в задачах распознавания образов и обработки графической информации// Научная библиотека диссертаций и авторефератов disserCat - <http://www.dissercat.com/content/prostye-reshayushchie-pravila-v-zadachakh-raspoznavaniya-obrazov-i-obrabotki-graficheskoi-in>, 1995.
- [6] Пахомов, П.А. Исследование сигнатур пикселей гиперспектрального изображения методом эмпирических мод/ П.А. Пахомов, А.В. Борусяк, В.Е. Турлапов //Сборник трудов ГМеждународной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ-2018). – Самара, 2018.
- [7] Федосеев, В.А. Классификация гиперспектральных спутниковых изображений по эталонным участкам территории /В.А. Федосеев //Сборник трудов IV международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ-2018). – Самара, 2018.
- [8] Wang, J. Independent component analysis-based dimensionality reduction with applications in hyperspectral image analysis / J. Wang, C.-I. Chang // IEEE Trans. Geosci. Remote Sens. –2006. – Vol. 44 (6). – P. 1586-1600.

Об авторах

Лебедев Леонид Иванович, к.ф.-м.н., ведущий научный сотрудник Института информационных технологий, математики и механики Нижегородского государственного университета. Его e-mail lebedev@pmk.unn.ru.

Шахлан Анастасия Олеговна, магистрант кафедры компьютерные системы и сети факультета информатики и систем управления Московского государственного технического университета. Ее e-mail amega123@mail.ru.