

УДК 004.021

МОДЕРНИЗИРОВАННЫЙ АЛГОРИТМ КЛАСТЕРИЗАЦИИ НЕЙРОННОЙ КАРТОЙ КОХОНЕНА В ЗАДАЧЕ ОБРАБОТКИ ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ

М. Н. Гурьева, старший инженер, Сбербанк-Технологии, Рязань; maria_guryeva@mail.ru

Рассматривается задача улучшения результатов кластеризации гиперспектрального изображения для возможности последующей идентификации объектов. В качестве метода оптимальной кластеризации представлена нейронная карта Кохонена с автоматическим определением количества классов объектов. Представлены результаты влияния фильтров нескольких типов на показатели качества кластеризации.

Целью работы является нахождение оптимального метода предварительной поканальной фильтрации трехмерного массива данных. Показателями качества приняты скорость предварительной настройки и построения карты, количество автоматически обнаруженных групп объектов.

Ключевые слова: кластеризация, гиперспектральные изображения, нейронная карта, фильтрация, дистанционное зондирование Земли.

DOI: 10.21667/1995-4565-2018-64-2-55-61

Введение

В настоящее время исследование гиперспектральной информации в дистанционном зондировании Земли получает интенсивное развитие и применение. Гиперспектральные изображения (ГСИ) представляют собой набор данных о регистрируемой на момент съемки спектральной плотности энергетической яркости (СПЭЯ) поверхности Земли на входном зрачке аппаратуры, содержащий в себе изображения одной и той же сцены в большом количестве узких соприкасающихся спектральных диапазонов. Каждая пространственная координата на изображении дополняется спектральной информацией на всем регистрируемом диапазоне. В результате формируется трехмерный массив (гиперкуб), состоящий из спектральных характеристик (СХ) каждой точки сцены в виде вектора отсчетов яркости в каждом регистрируемом спектральном канале. Спектральное разрешение ГСИ на порядок выше, чем у мультиспектральных изображений, что позволяет с большей точностью построить СХ анализируемой области, которая описывает распределение энергии излучения по длине волны (рисунок 1) [1].

Для получения таких снимков используется оптоэлектронная система, позволяющая одновременно производить замеры интенсивности солнечного освещения на большом числе длин волн.

При обработке таких данных исследование СХ каждого пикселя позволяет делать выводы о

химическом составе исследуемого объекта для дальнейшего более детального анализа.




Рисунок 1 – Спектральная характеристика на мультиспектральных и гиперспектральных данных

Результаты существующих исследований зависимости спектральной отражательной способности от длины волны падающего излучения объектов различного типа, таких как, например, растительность, открытая почва, антропогенные области, водная поверхность, позволяют по данным ДЗЗ делать выводы о качественных и коли-

чественных показателях анализируемого объекта. Например, в [2] представлен алгоритм идентификации загрязнений приповерхностного водного слоя по данным видеонаблюдения на основе оценки концентрации минеральных и органических веществ.

Постановка задачи

При обработке информации, поступающей со спутника, важным этапом является кластеризация, предназначенная для выделения однородных областей. При применении алгоритмов кластеризации можно выделить сегменты на изображении, определяющие зоны неоднородности спектральной характеристики. Это облегчает реализацию дальнейшего, более детального анализа.

Высокое разрешение космических снимков, а также большая размерность входных данных требует автоматизации процесса кластеризации. В настоящее время для обработки изображений широко применяются методы искусственного интеллекта.

Нейронная карта Кохонена

В настоящей работе для кластеризации разработана адаптация к входным данным в виде ГСИ метода самоорганизующейся нейронной карты Кохонена. Карта представляет собой нейронную сеть с обучением без учителя, содержащую один слой, количество нейронов в настоящей адаптации формируется автоматически и отражает количество распознанных классов. Итогом работы карты является проецирование многомерного пространства на пространство с более низкой размерностью, в данном случае – двумерное. Преимуществами этого метода являются устойчивость к зашумленным данным, быстрое и неуправляемое обучение, возможность упрощения многомерных входных данных с помощью визуализации [3]. В процессе анализа сеть большой входной выборки происходит вычисление общих признаков и группировка данных на кластеры. В настоящей реализации входной последовательностью сети является набор SX последовательности пространственных координат изображения, по которым необходимо выявить зависимость и оценить принадлежность этого пикселя к конкретному классу.

Первым этапом является формирование центральной выборки SX с одновременным автоматическим определением количества классов. Сформированная выборка далее используется в качестве эталонной при построении карты.

В классической реализации карты Кохонена первичная выборка представлена как последовательность векторов, заполненная случайными

числами. В контексте ГСИ это является неоптимальным, поскольку SX наблюдаемых объектов имеют определенную известную форму, например, водная поверхность имеет слабую отражательную способность в инфракрасной зоне, антропогенные области, напротив, высокую, а область лесополосы имеет два максимума SX – в зеленой и инфракрасной зоне спектра.

В настоящей реализации входная последовательность выбирается как набор SX пикселей, распределенных по изображению по методу чисел Фибоначчи, адаптированному на двумерный случай. Это представляет собой метод равномерного распределения точек, заключающийся в итеративном делении изображения на n частей по длине и ширине, как показано в формуле (1), и взятии спектральной характеристики SX центральной точки каждой части для анализа,

$$n_0 = 1, n_1 = 2, \dots, n_i = n_{i-1} + n_{i-2}. \quad (1)$$

Целью такого итеративного накопления является формирование выборки SX , максимально удаленных друг от друга по Евклидову расстоянию. На каждой итерации центральная выборка дополняется характеристиками по следующему алгоритму. Для каждого анализируемого вектора из последовательности (1) рассчитывается Евклидово расстояние до всех векторов центральной выборки, весовым коэффициентом данного вектора принимается минимальное из них

$$W = \min\{E_1, E_2, \dots, E_k\}, \quad (2)$$

где k – количество векторов текущей центральной выборки. По окончании итерации имеется n весовых коэффициентов. SX , соответствующие максимальным значениям $W_i > T$, где T – некоторое пороговое значение, добавляются к центральной выборке, после чего итерация повторяется для n_{i+1} входных параметров.

Критерием окончания поиска является резкое падение этого показателя по отношению к предыдущей итерации. Таким образом, на ГСИ автоматически определяется k характеристик, каждая из которых на следующем этапе является начальным центроидом для кластеризации.

Вторым этапом является настройка карты. Последовательность SX пикселей, распределенных по изображению в соответствии с вышеописанным принципом, подается на вход корректировочного алгоритма. Для каждой следующей анализируемой точки определяется Евклидово расстояние текущей спектральной характеристики до всех векторов центральной выборки. Вектор, расстояние до которого минимально, признается центральной корректировочной точкой, и происходит подстройка всей центральной выборки (3). В случае большого расстояния анали-

зируемой СХ до всех векторов центральной выборки эта точка признается принадлежащей новому классу и преобразовывается в самостоятельный весовой вектор

$$\begin{aligned} m(t) &= m(t-1) + h_c(t) \cdot (x(t) - m(t-1)), \\ h_c(t) &= \alpha(t) \cdot \delta(t), \\ \delta(t) &= e^{-\frac{R}{2\delta^2(t)}}, \end{aligned} \quad (3)$$

где $m(t)$ – скорректированный вектор, $m(t-1)$ – нескорректированный вектор, $x(t)$ – СХ текущего пикселя, $h_c(t)$ – корректировочная функция, $\alpha(t)$ – скорость обучения, $\delta(t)$ – функция соседства, определяющая количество соседних центроидов, которые затрагивает подстройка карты, R – расстояние на карте между центральной корректировочной точкой и корректируемым вектором. Скорость обучения определяет точность подстройки и на начальном этапе принимается равной 0,7. В процессе обучения сети этот коэффициент падает по экспоненциальной зависимости. Это означает, что на первых итерациях происходит жесткая корректировка, а на последних – «подстройка», что в конечном итоге приводит к формированию усредненной СХ каждого класса [4].

На третьем этапе вычисляется Евклидово расстояние СХ каждого пикселя исходного изображения до центральной выборки, на основании которого определяется принадлежность к определенному классу.

Таким образом, разработанный метод является классификатором ГСИ на группы пикселей с СХ близких признаков, в результате работы формируется и автоматически раскрашивается двумерная карта, разбитая на ячейки в соответствии с принадлежностью пикселей к тому или иному классу.

Калибровка исходных данных

Для калибровки исходных данных в коэффициенты спектральной яркости (КСЯ) необходимо провести радиометрическую и атмосферную коррекцию снимка. Снимки, первоначально получаемые со спутников, записаны в виде так называемых «сырых значений». Данные в таком формате нельзя адекватно сопоставить с данными других съемок. Задача радиометрической калибровки заключается в приведении этих значений в физические единицы.

В контексте ДЗЗ в видимом и ближнем инфракрасном диапазоне влияние атмосферы на световые волны выражается в несовпадении величин отраженной солнечной радиации, измеренных на Земле и зафиксированных на снимке

для областей одного типа. Главных факторов, вызывающих на снимке искажения величин СПЭЯ и КСЯ, два: это поглощение молекулами газов и рассеяние различных видов. Сила этих эффектов меняется для разных частей электромагнитного спектра. Для полного устранения атмосферных искажений на конкретном снимке необходимо знать пространственное распределение, концентрации, типы газов и аэрозолей над территорией в момент съемки. В этом случае используют физические алгоритмы атмосферной коррекции снимков, которые основаны на физических моделях переноса излучения в атмосфере, оценивают ряд параметров состояния слоя атмосферы с учетом географического положения территории и данных натурных метеонаблюдений в момент съемки для восстановления значения СПЭЯ поверхности, соответствующей каждому пикселю снимка. Для использования физических алгоритмов необходимо иметь численные значения некоторых параметров атмосферы в момент съемки в регионе. В числе программных реализаций таких алгоритмов модели FLAASH, ATCOR, MODTRAN и др. [5].




Рисунок 2 – RGB-модель (а) исходного и (б) прошедшего атмосферную коррекцию изображения

В рамках настоящей реализации атмосферная коррекция проводилась программной моделью MODTRAN. RGB-модель результатов коррекции представлена на рисунке 2.

Предварительная поканальная фильтрация ГСИ

Особенностью работы аппаратуры, регистрирующей ГСИ, является присутствие шумовой составляющей на изображении каждого канала, усиливающейся в коротковолновом спектре, что приводит к искажению СХ в этой зоне. Это замедляет поиск центральной выборки в вышеописанном алгоритме, приводит к появлению ложных классов и вносит неточности в результаты кластеризации. Реализована идея предварительной поканальной фильтрации ГСИ для сглаживания вектора СХ на всём спектральном диапазоне.

Для этого трехмерный массив исходных данных разбивается на каналы, каждый из которых представляет самостоятельное изображение в узком спектральном диапазоне и обрабатывается независимо. Для подавления зашумления в настоящей работе исследовано три типа фильтрации: сглаживающая фильтрация, медианная фильтрация, адаптивная фильтрация Винера.

Шумоподавляющий фильтр в настоящей реализации представлен следующими импульсными характеристиками, первая из которых формирует простой усредняющий фильтр:

$$\frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}, \frac{1}{10} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix}, \frac{1}{16} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix}, \quad (4)$$

где выходным массивом является последовательность вида (5):

$$y(i, j) = \sum_{l_1=0}^L \sum_{l_2=0}^L h(l_1, l_2) x(i-l_1, j-l_2), \quad (5)$$

где $h(l_1, l_2)$ – элементы массива H импульсной характеристики фильтра размерностью $L \times L$, $x(i, j)$ – элементы массива обрабатываемого изображения.

Медианный фильтр подавляет импульсные сигналы, длительность которых составляет менее половины ширины окна и вызывает уплощение вершины треугольных сигналов. Применительно к изображению с помощью медианного фильтра эффективно подавляются точечные шумовые выбросы. Выходной сигнал $y(i, j)$ скользящего медианного фильтра шириной $(2n+1)$ для текущего отсчета k формируется из входного временного ряда $\dots, x_{k-1}, x_k, x_{k+1}, \dots$ в соответствии с (6):

$$y_k = \text{med}(x_{k-n}, x_{k-n+1}, \dots, x_k, x_{k+1}, \dots, x_{k+n-1}, x_{k+n}), \quad (6)$$

где $\text{med}(x_1, \dots, x_m, x_{2n+1})$ – элементы вариационного ряда, т.е. ранжированные в порядке возрастания значений.

Адаптивная фильтрация Винера обеспечивает меньшую размытость контуров и мелких деталей по сравнению с описанными выше методами. Предполагается вычисление скорректированной яркости пиксела $y(i, j)$ на основе локальных оценок среднего значения $m(i, j)$ и дисперсии яркости $D(i, j)$ наблюдаемого изображения:

$$y(i, j) = m(i, j) + \frac{D(i, j) - \sigma_w^2}{D(i, j)} \cdot (f(i, j) - m(i, j)), \quad (7)$$

где σ_w^2 – дисперсия шумовой составляющей изображения.

На рисунке 3 приведены СХ одной и той же точки ГСИ без фильтрации и прошедшей адаптивную фильтрацию Винера. Можно отметить явное сглаживание СХ по всему спектральному диапазону с усилением этого эффекта в коротковолновой зоне спектра. Это указывает на то, что независимая обработка каждого канала ГСИ позволяет подавить зашумление СХ на всем спектральном диапазоне.

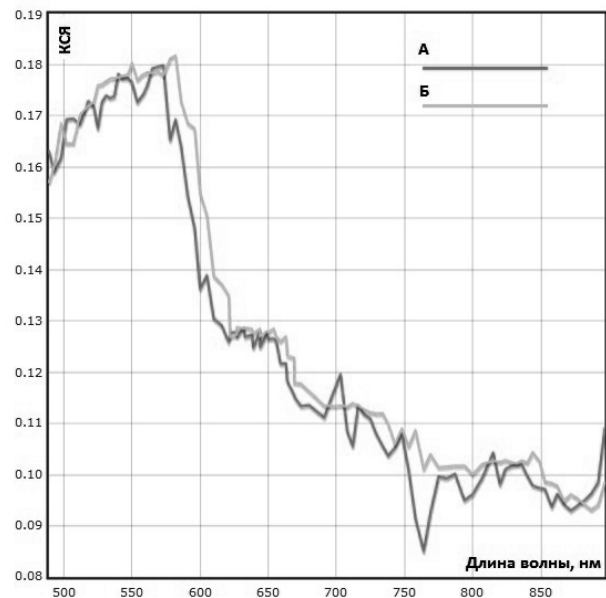


Рисунок 3 – СХ пиксела: А – без фильтрации, Б – адаптивная фильтрация Винера

Экспериментальные исследования

В рамках проведенного исследования разработанный алгоритм кластеризации с предварительной фильтрацией различного типа был применен на ГСИ города Регенсия (Эспириту-Санту, Бразилия). Снимок состоит из 128 каналов с пространственным разрешением ~ 20 м и спектральным разрешением ~ 5 нм.

Результаты кластеризации приведены на рисунке 4. Можно отметить, что применение фильтрации увеличивает количество распознанных классов, а также, что в случае использования шумоподавляющих фильтров различного типа результаты отличаются незначительно. Во всех случаях резко отличающиеся по СХ классы, такие как водная поверхность, суша, облачность, успешно идентифицированы, но в зависимости от примененного алгоритма предварительной фильтрации автоматически происходит кластеризация также внутри этих классов. Критерием оценки результатов выбраны время формирования первичной центральной выборки t_{nc} , время настройки t_{nm} , количество обнаруженных типов

объектов (суша, вода, облачность) n_1 , количество обнаруженных кластеров внутри каждого объекта n_2 .




Рисунок 4 – Результаты кластеризации ГСИ алгоритмом на основе карты Кохонена:
 А – исходное изображение, Б – без фильтрации,
 В – шумоподавление по маске 1/10,
 Г – шумоподавление по маске 1/16,
 Д – медианная фильтрация,
 Е – адаптивная фильтрация Винера

В таблице 1 приведены численные результаты проведенного эксперимента. На основе полученных результатов можно сделать вывод, что применение предварительной фильтрации ГСИ позволяет в зависимости от используемого фильтра в 7 – 8 раз уменьшить время формирования центральной выборки, в 4 – 5 раз уменьшить время настройки карты, в 2 – 3 раза увеличить количество распознанных классов. Наилучшие результаты обработки достигнуты при использовании адаптивной фильтрации Винера, поскольку количество распознанных зон неоднородностей объекта внутри кластера в этом случае является наибольшим при незначительном увеличении времени настройки и распознавания по сравнению с шумоподавляющим и медианным фильтром.

Вместе с тем резко отличающиеся кластеры, такие как водная поверхность, суша, облачность, успешно идентифицируются во всех случаях. В таблице 2 представлены среднее внутрикластерное Евклидово расстояние до центрального вектора и межклассовая дисперсия для рассмотренных методов фильтрации.

Таблица 1 – Численные результаты

Тип фильтрации	t_{nb}	t_{nm}	t_{cl}	n_1	n_2
Без фильтрации	80с	15с	4м	3	Вода – 2 Суша – 1
Шумоподавление 1/10	10с	3с	1м	3	Вода – 2 Суша – 2
Шумоподавление 1/16	10с	3с	1м	3	Вода – 2 Суша – 2
Медианная фильтрация	10с	3с	1м	3	Вода – 2 Суша – 3
Адаптивная фильтрация Винера	12с	4с	1м	3	Вода – 3 Суша – 3

Таблица 2 – Среднее внутрикластерное расстояние и межкластерная дисперсия

Тип фильтрации	E_{cp}	σ^2
Без фильтрации	0.46	0.29
Шумоподавление 1/10	0.44	0.15
Шумоподавление 1/16	0.39	0.11
Медианная фильтрация	0.43	0.16
Адаптивная фильтрация Винера	0.35	0.08

Выводы

В статье предложен алгоритм кластеризации ГСИ нейронной картой Кохонена. Предлагаемая в работе реализация нейронной карты по сравнению с [4] дополнена алгоритмом автоматического определения количества классов, что существенно повышает точность сформированной центральной выборки, поскольку первичная последовательность представлена не векторами, заполненными случайными числами, а реальными максимально различающимися СХ пикселей изображения, что в конечном итоге положительно сказывается на результате кластеризации, уменьшая внутрикластерное Евклидово расстояние до центрального вектора на 5-25 % и понижая межклассовую дисперсию на 50-73 %, в зависимости от выбранного метода фильтрации.

Для уменьшения времени предварительной настройки и улучшения качества работы алгоритма рассмотрена идея метода предваритель-

ной поканальной фильтрации ГСИ. Результатом применения этого метода является уменьшение показателей качества работы карты кластеризации по отношению к изображению без применения фильтрации: времени формирования первичной выборки на 85%, времени настройки карты на 80%.

Исследовано влияние трех типов фильтров на показатели качества кластеризации: шумоподавляющего, медианного, фильтра Винера. В результате проведенного исследования установлено, что применение предварительной фильтрации на 75% снижает время формирования карты кластеризации и в 3 раза – порог различия СХ распознаваемого типа объектов.

Заключение

Предложенный метод кластеризации может использоваться для выделения зон однородности на местности при космической или аэро съемке, для оценки показателей качества лесополосы, сельхозугодий, прибрежных акваторий по центральной характеристике каждого кластера. Возможно применение методики «в обратную сторону» для системного мониторинга околоземного космического пространства и распознавания покрытий космических аппаратов оптическими средствами [6].

Дальнейшее увеличение количества распознанных классов возможно с применением алгоритма spectral unmixing, модернизацией вычисляемой меры близости векторов, проведением дополнительной кластеризации по рассчитываемым по СХ индексам, таким как NDVI в случае

зоны растительности, индекс увлажненности в случае зоны сельхозугодий, биооптический индекс для водной поверхности.

Библиографический список

1. Демидова Л. А., Еремеев В. В., Мятлов Г. Н., Тишкин Р. В., Юдаков А. А. Сегментация объектов по данным гиперспектральной съёмки Земли с использованием методов искусственного интеллекта // Вестник Рязанского государственного радиотехнического университета. 2014. № 3(49). С. 3-10.
2. Григорьева О. В., Шилин Б. В. Опыт оценки экологических характеристик акваторий морских портов по данным видеоспектральной съёмки // Современные проблемы дистанционного зондирования Земли из космоса. 2012. Т. 9. № 1. С. 156-166.
3. Горбаченко В. И. Сети и карты Кохонена: [Электронный ресурс] // Научно-исследовательский центр самоорганизации и развития систем. М., 2010 – 2014. URL: <http://gorbachenko.self-organization.ru/>.
4. Гурьева М. Н. Применение самоорганизующейся карты Кохонена для сегментации гиперспектральных изображений // Юбилейная 25-я международная конференция «GRAPHICON 2015» АНО научного общества «ГРАФИКОН» Института физико-технической информатики, Протвино, 22 – 25 сентября 2015 г.: Труды. 2015. С. 93-95.
5. Деркачева А. А., Тутубалина О. В. Эффективность атмосферных коррекций гиперспектральных снимков Nuregion в регионах с развитым растительным покровом // Современные проблемы дистанционного зондирования Земли из космоса. 2014. Т. 11. № 4. С. 360-368.
6. Миронов В. В., Муртазов А. К., Усовик И. В. Системные методы мониторинга околоземного космического пространства / под науч. ред. проф. Миронova В.В. – Рязань: Book Jet, 2017. 318 с.

UDC 004.021

MODERNIZED ALGORITHM OF CLUSTERING WITH KOHONEN NEURAL MAP IN THE PROBLEM OF PROCESSING HYPERSPECTRAL IMAGES

M. N. Guryeva, Senior Engineer, Sberbank-Technologies, Ryazan; maria_guryeva@mail.ru

The problem of improving the results of clustering a hyperspectral image for the possibility of subsequent identification of objects is considered. As a method of optimal clustering, a neural map of Kohonen with an automatic determination of object class number is presented. The results of the influence of several types of filters on the quality of clustering are presented.

The aim of the work is to find the optimal method for pre-filtering channel plane section of a three-dimensional array of data. Quality indicators include the speed of presetting and building a map, the number of automatically detected groups of objects.

Key words: clustering, hyperspectral images, neural map, filtration, remote Earth sensing.

DOI: 10.21667/1995-4565-2018-64-2-55-61

References

1. **Demidova L. A., Ereemeev V. V., Mjatov G. N., Tishkin R. V., Judakov A. A.** Segmentacija ob#ektov po dannym giperspektral'noj sjomki Zemli s ispol'zovaniem metodov iskusstvennogo intellekta. Vestnik Rjazanskogo gosudarstvennogo radiotekhnicheskogo universiteta. 2014. No. 3(49). pp. 3-10. (in Russian).
2. **Grigorjeva O. V., Shilin B. V.** Opyt ocenki jekologicheskikh harakteristik akvatorij morskikh portov po dannym videospektral'noj sjemki. Sovremennye problemy distancionnogo zondirovanija Zemli iz kosmosa. 2012. Vol. 9. No. 1. pp. 156-166 (in Russian).
3. **Gorbachenko V. I.** Seti i karty Kohonena: [Jelektronnyj resurs]. Nauchno-issledovatel'skij centr samoorganizacii i razvitija sistem. M., 2010-2014. URL: <http://gorbachenko.self-organization.ru/> (in Russian).
4. **Gurjeva M. N.** Primenenie karty Kohonena dlja segmentacii giperspektral'nyh izobrazhenij. Jubilejnaja 25-ja mezhdunarodnaja konferencija «GRAPHICON 2015» ANO nauchnogo obshhestva «GRAFIKON» Instituta fiziko-tehnicheskoy informatiki, Protvino, 22-25 sentjabrja 2015.: Trudy. 2015. pp. 93-95 (in Russian)
5. **Derkacheva A. A., Tutubalina O. V.** Jeffektivnost' atmosferynyh korrekcij giperspektral'nyh snimkov Hyperion v regionah s razvitym rastitel'nym pokrovom. Sovremennye problemy distancionnogo zondirovanija Zemli iz kosmosa. 2014. Vol. 11. No 4. pp. 360-368 (in Russian).
6. **Mironov V. V., Murtazov A. K., Usovik I. V.** Sistemnye metody monitoringa okolozemnogo kosmicheskogo prostranstva / pod nauch. red. prof. Mironova V.V. – Rjazan': Book Jet, 2017. P. 318. in Russian).