

СЕГМЕНТАЦИЯ ОБЪЕКТОВ ПО ДАННЫМ ГИПЕРСПЕКТРАЛЬНОЙ СЪЕМКИ ЗЕМЛИ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Демидова Л.А., д.т.н., профессор кафедры ВПМ РГРТУ

Еремеев В.В., д.т.н., профессор, директор НИИ «Фотон» РГРТУ, e-mail: foton@rsreu.ru

Мятов Г.Н., к.т.н., заместитель начальника НПЦ ИТ ДЗЗ ФГУБ «ГНПРКЦ «ЦСКБ-Прогресс»,

Тишкин Р.В., к.т.н., доцент, начальник отдела филиала ФГУБ «ГНПРКЦ «ЦСКБ-Прогресс» – ОКБ «Спектр»,

Юдаков А.А., начальник научно-производственного отдела создания и эксплуатации специальных наземных комплексов ФГУБ «ГНПРКЦ «ЦСКБ-Прогресс»

Ключевые слова: гиперспектральные изображения, сегментация, спектральная характеристика, методы искусственного интеллекта.

Введение

Гиперспектральная съемка является приоритетным направлением развития систем дистанционного зондирования Земли (ДЗЗ). Она предполагает одновременное получение сотен и тысяч изображений одной и той же сцены, зафиксированных в очень узких соприкасающихся диапазонах спектра. В результате формируется многомерное гиперспектральное изображение (ГСИ), называемое гиперкубом. Каждой точке земной поверхности гиперкуб ставит в соответствие спектральную характеристику (СХ), которая описывает распределение энергии излучения по длине волны. Знание СХ для множества точек вполне определенных объектов позволяет автоматизировать процесс сегментации объектов и установить их физико-химические свойства. Поэтому материалы гиперспектральной съемки находят широкое применение во многих сферах человеческой деятельности: экологии, сельском и лесном хозяйствах, анализе атмосферы, поиске полезных ископаемых, военной сфере и др.

Гиперспектральная съемка начала внедряться в практику ДЗЗ совсем недавно. За рубежом работы в этом направлении начаты 12 лет назад и активно развиваются. В нашей стране впервые гиперспектральная аппаратура (ГСА) выведена на орбиту на спутнике МКА-ФКИ (головной разработчик – НПО им. С.А. Лавочкина) в июле 2012 года, а 25 июня 2013 года запущен КА «Ресурс-П» на котором установлена ГСА, работающая в 130 узких соприкасающихся диапазонах видимой области спектра.

ГСИ – это принципиально новый вид информации о земной поверхности, развитие средств ее получения и обработки находятся в самой начальной стадии. Основной задачей, для решения которой собственно и создается ГСА, является повышение уровня автоматизации процессов сегментации и последующей классификации объектов наблюдаемой сцены.

Анализ характерных свойств ГСИ гиперспектральных изображений показывает наличие сильной корреляции между отдельными элементами гиперкуба как в пространственной, так и в спектральной области. Другой характерной особенностью ГСИ является значительное

Рассматриваются вопросы автоматического выделения объектов земной поверхности на основе анализа материалов гиперспектральной съемки. Для решения этой задачи обосновано использование методов искусственного интеллекта. Представлены результаты обработки натурной гиперспектральной информации.

влияние на спектральные характеристики ряда искажающих факторов: условий съемки и освещенности земной поверхности, состояния атмосферы, сезонности наблюдений, погодных условий и др. Все это вносит некоторую неопределенность в отображение объектов, регистрируемых в различных спектральных диапазонах, и, кроме того, приводит к размытию границ переходов от одного объекта к другому. В связи с этим авторы считают, что одним из перспективных направлений по сегментации объектов на ГСИ является совместное применение алгоритмов кластеризации в условиях неопределенности (в частности, FCM-, PCM- и PFCM-алгоритмов), обеспечивающих разбиение на кластеры с учетом свойств кластерной относительности и/или кластерной типичности. В настоящей работе рассматриваются первые результаты исследований по комплексному применению данных алгоритмов для сегментации ГСИ.

Кластеризация ГСИ в условиях неопределенности

Кластеризация ГСИ в условиях неопределенности заключается в нахождении разбиения исходного множества точек ГСИ, образующих некоторую структуру кластеров, т.е. в нахождении степеней принадлежности или/и типичности точек ГСИ искомым кластерам.

Наиболее известными алгоритмами кластеризации, основанными на учете того или иного вида неопределенности, является алгоритм нечетких c -средних (fuzzy c -means; FCM-алгоритм) [1] и его модификации: алгоритм возможных c -средних (possibilistic c -means; PCM-алгоритм) [2] и алгоритм возможных нечетких c -средних (possibilistic fuzzy c -means; PFCM-алгоритм) [3]. FCM-алгоритм основан на учете свойства кластерной относительности, PCM-алгоритм – на учете свойства кластерной типичности, PFCM-алгоритм – на одновременном учете свойств кластерной относительности и типичности объектов (точек ГСИ). Рассмотрим использование этих алгоритмов с учетом специфики решения задачи сегментации точек ГСИ, основываясь на трудах зарубежных авторов [1, 2, 3].

Гиперспектральное изображение можно представить в виде множества точек $x_i = \{x_i^l; l = \overline{1, q}\}$, $i = \overline{1, n}$, где n – количество точек изображения, а q – количество спектральных каналов.

FCM-, PCM- и PFCM-алгоритмы основаны на минимизации соответственно целевых функций [1-3, 4, 5]:

$$J(U, V) = \sum_{j=1}^c \sum_{i=1}^n u_j^m(x_i) \cdot d_{ji}^2 \rightarrow \min; \quad (1)$$

$$J(W, V) = \sum_{j=1}^c \sum_{i=1}^n w_j^m(x_i) \cdot d_{ji}^2 +$$

$$+ \sum_{j=1}^c \eta_j^2 \cdot \sum_{i=1}^n (1 - w_j(x_i))^m \rightarrow \min;$$

$$J(U, W, V) = \sum_{j=1}^c \sum_{i=1}^n (u_j(x_i)^m + w_j(x_i)^{m'}) \cdot d_{ji}^2 \rightarrow \min; \quad (3)$$

где $U = [u_j(x_i)]$ – нечеткое c -разбиение множества точек X на основе функций принадлежности $u_j(x_i)$ спектральных характеристик точки ГСИ x_i кластеру X_j ;

$W = [w_j(x_i)]$ – возможностное c -разбиение множества точек X на основе функций типичности $w_j(x_i)$, определяющих возможностную степень типичности точки ГСИ x_i кластеру X_j ($j = \overline{1, c}$); $V = (v_1, \dots, v_c)$ – центры кластеров; d_{ji} – расстояние между центром кластера v_j и

точкой изображения x_i : $d_{ji}^2 = \sum_{l=1}^q (x_i^l - v_j^l)^2$; x_i^l – яркость в l -м канале для i -й точки; v_j^l – l -я координата центра j -го кластера; m и m' – фаззификаторы ($m, m' \in R$, $m > 1$, $m' > 1$); c – количество кластеров, которое считается предварительно заданным; η_j ($j = \overline{1, c}$) – «ширина зоны», определяющая расстояние, на котором

значение функции типичности точки ГСИ кластеру X_j равно 0,5: $\eta_j = (\sum_{i=1}^n (u_j(x_i)^m \cdot d_{ji}^2) / \sum_{i=1}^n u_j(x_i)^m)^{0,5}$.

Функции принадлежности $u_j(x_i)$ и типичности $w_j(x_i)$ определяются как

$$u_j(x_i) = 1 / \sum_{k=1}^c (d_{ji} / d_{ki})^{2/(m-1)}; \quad (4)$$

$$w_j(x_i) = 1 / (1 + (d_{ji} / \eta_j)^{2/(m-1)}). \quad (5)$$

При этом $\sum_{j=1}^c u_j(x_i) = 1$; $\sum_{j=1}^c w_j(x_i) = 1$ ($i = \overline{1, n}$).

Центры кластеров при реализации FCM-, PCM-, PFCM-алгоритмов соответственно рассчитываются по формулам:

$$v_j^l = \sum_{i=1}^n (u_j(x_i))^m \cdot x_i^l / \sum_{i=1}^n (u_j(x_i))^m; \quad (6)$$

$$v_j^l = \sum_{i=1}^n (w_j(x_i))^m \cdot x_i^l / \sum_{i=1}^n (w_j(x_i))^m; \quad (7)$$

$$v_j^l = \frac{\sum_{i=1}^n \left((u_j(x_i))^m + (w_j(x_i))^{m'} \right) \cdot x_i^l}{\sum_{i=1}^n \left((u_j(x_i))^m + (w_j(x_i))^{m'} \right)}. \quad (8)$$

В результате экспериментальных исследований с использованием натурной информации от гиперспектральной аппаратуры Nuregon, AVIRIS, HYDICE, «Сокол-ГЦП» установлено, что для получения адекватных результатов кластеризации с применением FCM-, PCM- и PFCM-алгоритмов необходимо осуществить их многократное выполнение для различных исходных разбиений при фиксированном количестве кластеров c ; выполнить сравнение значений целевой функции и выбрать для дальнейшего анализа разбиение с ее минимальным значением.

Повышение качества сегментации ГСИ с использованием генетических алгоритмов


Для повышения качества сегментации ГСИ на основе алгоритмов кластеризации в условиях неопределенности целесообразно привлечение генетических алгоритмов (ГА) [6] с целью уточнения центров кластеров [4, 7]. Применительно к кластеризации ГСИ для заданного количества кластеров c каждая хромосома может быть закодирована координатами центров кластеров (спектральными характеристиками кластеров).

При комбинировании алгоритма кластеризации в условиях неопределенности (FCM-, PCM- или PFCM-алгоритма) и ГА в качестве функции соответствия может быть использована соответствующая целевая функция алгоритма кластеризации или некоторый показатель качества кластеризации, например, в случае использования FCM-алгоритма – индекс Се-Бени XB [8]:

$$XB = \frac{\sum_{j=1}^c \sum_{i=1}^n (u_j(x_i))^2 \cdot \sum_{l=1}^q (x_i^l - v_j^l)^2}{n \cdot \min_{t \neq j} \sum_{l=1}^q (v_t^l - v_j^l)^2} \rightarrow \min, t = \overline{1, c}. \quad (9)$$

Индекс Се-Бени XB учитывает нечеткие степени принадлежности объектов ГСИ центрам кластеров, а также их геометрическое расположение и является наиболее информативным показателем качества кластеризации при оценке компактности и хорошей делимости кластеров. Как показывает практика, при хороших результатах нечеткой кластеризации $XB < 1$. В качестве искомого количества кластеров c целесообразно выбирать то, для которого индекс Се-Бени XB принимает минимальное значение.

Если искомое количество кластеров заранее известно, то при кодировании хромосомы координатами центров кластеров длина хромосомы будет равна $c \cdot q$. При этом первые q элементов хромосомы будут соответствовать координатам центра первого кластера,



вторые q элементов – координатам центра второго кластера и т.д. Если оптимальное количество кластеров заранее неизвестно, то в ГА длина хромосомы может варьироваться от $c_{\min} \cdot q$ до $c_{\max} \cdot q$. В общем случае, хромосома, кодирующая координаты центров кластеров, может быть представлена как [7]:

$$s = (v_1^1, v_1^2, \dots, v_1^q, \dots, v_c^1, v_c^2, \dots, v_c^q). \quad (10)$$

При создании начальной популяции хромосом, кодирующих координаты центров кластеров, при сегментации ГСИ может быть реализован следующий подход. Сначала в пространстве значений спектральных характеристик с некоторым постоянным шагом h (в каждом канале) фиксируются узловые точки, потенциально являющиеся координатами центров кластеров. Далее эти узловые точки некоторым образом группируются для формирования хромосом вида (10), определяющих разбиение множества точек ГСИ на заданное количество кластеров c^* ($c_{\min} \leq c^* \leq c_{\max}$). При этом общее количество «потенциальных» хромосом должно в 4-5 раз превосходить размер будущей популяции.

Для выбора хромосом-родителей может быть использован вероятностный отбор, в соответствии с которым для каждой хромосомы s_g на основе значения ее функции соответствия $FF(s_g)$ ($g = \overline{1, G}$) вычисляется вероятность [4]:

$$p_g = \frac{\overline{FF}(s_g)}{\sum_{k=1}^G \overline{FF}(s_k)}, \quad g = \overline{1, G}, \quad (11)$$

где $\overline{FF}(s_g) = \max_{k=1, G} (FF(s_k)) - FF(s_g)$; $\sum_{g=1}^G p_g = 1$; G – размер популяции.

В соответствии с формулой (11) приспособленность хромосомы s_g тем выше, чем меньше соответствующее ей значение функции соответствия $FF(s_g)$.

Вероятностный отбор хромосом-родителей может быть выполнен следующим образом.

Шаг 1. На горизонтальной оси откладывается ряд чисел p_g ($g = \overline{1, G}$).

Шаг 2. Генерируется случайное число z в диапазоне $[0, 1]$.

Шаг 3. В качестве первой хромосомы-родителя выбирается хромосома s_g , если случайное число z попало в g -й интервал: $[p_{g-1}, p_g]$, где $p_0 = 0$.

Шаги 2 и 3 повторяются для определения второй хромосомы-родителя.

Выбранная таким образом пара хромосом-родителей используется при выполнении операции скрещивания.

Обычно в классическом ГА реализуется одноточечное скрещивание и мутация с коэффициентом скрещивания и коэффициентом мутации, выбираемыми соответственно из отрезков $[0, 7; 0, 8]$ и $[0, 01; 0, 02]$. В контексте решения задачи сегментации ГСИ следует исполь-

зовать большее количество точек скрещивания и мутации (от 3 до 5) ввиду работы с хромосомами существенно большей длины, чем при решении большинства аналогичных задач кластеризации данных.

Совместное применение ГА, например, с FCM-алгоритмом для сегментации ГСИ описывается следующей последовательностью шагов.

Шаг 1. Для формирования начальной популяции хромосом размером G выполняется один шаг FCM-алгоритма с вычислением значений индекса Се-Бени (9).

Шаг 2. При выполнении условия продолжения ГА осуществляется один шаг ГА с реализацией операций скрещивания и мутации и вычислением индекса Се-Бени (9) для хромосом популяции размером $2 \cdot R_c \cdot G$, состоящей из хромосом-потомков, где R_c – коэффициент скрещивания.

Шаг 3. Для популяции размером $(G + 2 \cdot R_c \cdot G)$ выполняется один шаг FCM-алгоритма с вычислением значений функций принадлежности (нечетких степеней принадлежности) объектов центрам кластеров в соответствии с формулой (4), координат центров кластеров в соответствии с формулой (6). Затем осуществляется уточняющий пересчет значений функций принадлежности (нечетких степеней принадлежности) объектов новым центрам кластеров в соответствии с формулой (6) и вычисление индекса Се-Бени (9) для нового набора центров кластеров.

Шаг 4. Из расширенной популяции хромосом размером $(2 \cdot G + 2 \cdot R_c \cdot G)$, полученной путем объединения популяции размером G предыдущего поколения и популяции размером $(G + 2 \cdot R_c \cdot G)$ текущего поколения, удаляются $(G + 2 \cdot R_c \cdot G)$ хромосом с худшими (максимальными) значениями индекса Се-Бени (9). Если выполняется условие продолжения генетического алгоритма, осуществляется переход к шагу 2, иначе переход к шагу 5.

Шаг 5. Выбирается лучшая хромосома, которая минимизирует функцию соответствия (индекс Се-Бени (9)). В качестве искомым координат центров кластеров берутся координаты центров кластеров, соответствующие лучшей хромосоме. Выполняется сегментация ГСИ на основе полученного набора координат центров кластеров.

Сегментация ГСИ с использованием ансамбля алгоритмов

Каждый из рассмотренных выше алгоритмов кластеризации реализует сегментацию ГСИ на отдельные образования, не учитывая при этом всё многообразие взаимосвязей между точками ГСИ. В связи актуальной является задача консолидации результатов сегментации ГСИ, полученных от различных алгоритмов кластеризации.

Для решения данной задачи разработан ансамбль алгоритмов кластеризации [9], основанный на применении ГА для максимизации количества взаимной информации, содержащейся в частных результатах кластеризации, и обеспечивающий получение консолидированного вектора меток кластеров, описывающего искомую кластерную принадлежность точек ГСИ.

Пусть в результате применения R частных алгорит-

мов кластеризации для сегментации ГСИ формируется R векторов меток кластеров. При этом каждый r -й частный алгоритм сегментации дает разбиение на c^r кластеров ($r = \overline{1, R}$), описываемое вектором меток кластеров λ^r . Функция Γ , реализующая отображение $N^{n \times R} \rightarrow N$ частных решений о результатах кластеризации в одно консолидированное решение, определяется как

$$\Gamma: \{\lambda^r \mid r \in \{1, \dots, R\}\} \rightarrow \lambda.$$

При отсутствии априорной информации об относительной значимости того или иного частного решения функция Γ определяется из условия максимального использования информации из частных решений. Для этого применена функция нормализованной взаимной информации (normalized mutual information (NMI)):

$$\varphi^{NMI}(\lambda^a, \lambda^b) = \frac{\sum_{h=1}^{c^a} \sum_{l=1}^{c^b} \left[n_{hl} \cdot \log \left(\frac{n \cdot n_{hl}}{n_h^a \cdot n_l^b} \right) \right]}{\sqrt{\left(\sum_{h=1}^{c^a} n_h^a \cdot \log \left(\frac{n_h^a}{n} \right) \right) \cdot \left(\sum_{l=1}^{c^b} n_l^b \cdot \log \left(\frac{n_l^b}{n} \right) \right)}},$$

где λ^a и λ^b – вектора меток кластеров; n_h^a и n_l^b – количество точек в h -м и l -м кластерах; n_{hl} – количество точек, которые в h -м кластере соответствуют меткам из вектора меток кластеров λ^a так же, как в l -м кластере соответствуют меткам из вектора меток кластеров λ^b .

Средняя нормализованная взаимная информация (average NMI – (ANMI)) для множества A частных решений о результатах кластеризации и консолидированного вектора меток кластеров $\hat{\lambda}$ может быть определена как

$$\varphi^{ANMI}(A, \hat{\lambda}) = \frac{1}{R} \cdot \sum_{r=1}^R \varphi^{NMI}(\tilde{\lambda}^r, \hat{\lambda}^r).$$

При разработке ансамбля алгоритмов кластеризации был использован ГА, позволивший осуществить поиск консолидированного вектора меток кластеров $\hat{\lambda}$ с приемлемыми временными затратами.

При этом при формировании начальной популяции хромосом предлагается использовать векторы меток кластеров, полученные в результате реализации частных алгоритмов кластеризации.

При вычислении консолидированного вектора меток кластеров частные векторы меток кластеров могут рассматриваться как равновесные, так и неравновесные. В последнем случае вычисление весовых коэффициентов

частных алгоритмов кластеризации основано на оценке количества однозначно классифицируемых точек конкретного ГСИ.

Экспериментальные исследования на реальных данных гиперспектральной съемки показали, что использование для кластеризации ансамбля различных алгоритмов кластеризации повышает долю верно кластеризуемых элементов ГСИ на 5-7%. Этот показатель является усредненным по всем рассмотренным вариантам использования ансамбля алгоритмов кластеризации.

Заключение

Рассмотренные выше алгоритмы сегментации ГСИ прошли экспериментальную отработку на натурной информации от ГСА отечественного и зарубежного производства как космического, так и авиационного базирования. В табл. 1 представлены результаты этих исследований в виде доли ложных идентификаций точек ГСИ (в процентах), усредненные по нескольким гиперкубам. В качестве эталона использовались результаты автоматизированной сегментации с участием оператора.

На рис. 1 представлен пример сегментации ГСИ на основе совместного использования FCM-алгоритма и ГА.

На рис. 2 в качестве примера слева представлен результат сегментации ГСИ с использованием PFCM-алгоритма (доля ложных идентификаций – 8,9%), а справа – с использованием ансамбля алгоритмов (доля ложных идентификаций – 5,6%).

В настоящее время после ввода в штатную эксплуатацию КА «Ресурс-П» исследования рассмотренных в настоящей работе алгоритмов продолжают [10, 11, 12] с целью повышения эффективности их работы.

Настоящая работа выполнена при финансовой поддержке РФФИ (грант ОФИ-М-2013 № 13-01-12014).

Литература

1. Bezdek J.C., Ehrlich R., Full W. FCM: Fuzzy C-Means Algorithm // Computers and Geoscience, 1984. – Vol. 10. – № 2. – P. 191-203.
2. Krishnapuram R., Keller J. A possibilistic approach to clustering. – IEEE Transactions on Fuzzy Systems, vol. 1, 1993. – pp. 98-109.
3. Choi T.-M., Kim S.Y. Fuzzy Types Clustering for Microarray Data // Proceedings of world academy of science, engineering and technology, 2005. – Vol. 4. – P. 12-15.
4. Демидова Л.А., Кираковский В.В., Пылькин А.Н. Принятие решений в условиях неопределенности. – М.: Горячая линия – Телеком, 2012. – 288 с.
5. Тишкин Р.В., Юдаков А.А. Субпиксельная классификация объектов на космических гиперспектральных изображениях // Цифровая обработка сигналов. 2012. №3. С. 49-51.

Таблица 1. Результаты исследований алгоритмов идентификации ГСА

Экспериментальный материал	FCM-алгоритм	PCM-алгоритм	PFCM-алгоритм	Ансамбль алгоритмов
5 гиперкубов от ГСА «Сокол» (РФ)	12,4	15,7	9,2	4,3
6 гиперкубов от ГСА AVIRIS (США)	13,1	16,9	8,9	5,6
8 гиперкубов от ГСА Hyperion (США)	12,7	16,1	10,1	4,9



Рис. 1. Сегментация исходного ГСИ (слева) на основе совместного использования FCM-алгоритма и генетического алгоритма (справа)





Рис. 2. Сегментация ГСИ с использованием PFCM-алгоритма и ансамбля алгоритмов кластеризации

6. Nachouf F., Zeggari A. Genetic optimization for unsupervised fuzzy classification // 17 Congress Mondial IMACS, 2005. – P. 27-32.

7. Тишкин Р.В., Юдаков А.А. Сегментация гиперспектральных изображений с применением алгоритмов кластеризации в условиях неопределенности, генетических алгоритмов и нейронных сетей // Математическое и программное обеспечение вычислительных систем: межвуз. сб. науч. тр. Рязань: РГРТУ, 2013. С. 124-138

8. Xei X.L., Beni G.A. Validity Measure for Fuzzy Clustering // IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991. – № 3(8). – P. 841-846.

9. Демидова Л.А., Юдаков А.А. Сегментация гиперспектральных изображений с применением ансамбля алгоритмов кластеризации // Программные информационные системы: межвуз. сб. науч. тр. Рязань: РГРТУ, 2013. С. 33-49.

10. Ахметов Р.Н., Стратилатов Н.Р., Юдаков А.А., Везенов В.И., Еремеев В.В. Некоторые примеры обработки гиперспектральных изображений // Исследование Земли из космоса. 2013. №6. С. 35-39.

11. Антонушкина С.В., Еремеев В.В., Макаренков А.А., Москвитин А.Э. Особенности анализа и обработки информации от систем гиперспектральной съемки земной

поверхности // Цифровая обработка сигналов. 2010. № 4. С. 38-45.

12. Еремеев В.В., Макаренков А.А., Москвитин А.Э., Юдаков А.А. Повышение четкости отображения объектов на данных гиперспектральной съемки земной поверхности // Цифровая обработка сигналов. 2012. №3. С.35-39.

SEGMENTATION OF EARTH SURFACE HYPERSPETRAL IMAGERY BASED ON ARTIFICIAL INTELLIGENCE TECHNIQUES

*Demidova L.A., Ereemeev V.V., Myatov G.N.,
Tishkin R.V., Yudakov A.A.*

Automatic object recognition on hyperspectral imagery of Earth surface were discussed in the article. Involvement of artificial intelligence techniques for object recognition on hyperspectral imagery is considered. Fuzzy clusterization of hyperspectral imagery with FCM-, PCM- and PFCM-algorithms were described. Approaches of quality increase of clusterization by applying genetic algorithms were presented. Forming of clustering ensemble for hyperspectral data processing were described. Clusterization algorithms were evaluated in the conclusion.