

Romm Yakov Evseevich

Taganrog State Pedagogical Institute.

E-mail: romm@list.ru.

48, Initsiativnaya street, Taganrog, 347926, Russia.

Phone: +78634601753, +78634601812, +78634601807

Koryakin Alexey Borisovich

JSC "Taganrog Plant PRIBOY".

E-mail: alexis@koryakin@mail.ru.

13, B. Bul'varnaya street, Taganrog, 347913, Russia.

Phone: +78634601753.

УДК 004.932.2

Е.А. Вершовский**РОЕВОЙ АЛГОРИТМ ОПТИМИЗАЦИИ В ЗАДАЧЕ КЛАСТЕРИЗАЦИИ
МУЛЬТИСПЕКТРАЛЬНОГО СНИМКА**

Статья содержит алгоритм кластеризации мультиспектрального снимка на основе оптимизации роя частиц. Актуальность работы связана с актуальностью разработок в области роевого интеллекта и актуальностью задач дешифрирования мультиспектральных космических снимков.

Оптимизация роя частиц; кластеризация мультиспектральных изображений; K-means; ISODATA / particle swarm optimization; multispectral image clustering; K-means; ISODATA.

E.A. Vershovsky**SWARM OPTIMIZATION ALGORITHM IN THE MULTISPECTRAL IMAGES
CLUSTERING TASK**

The article contains an algorithm for clustering multispectral images based on swarm particle optimization. The urgency of the work associated with the relevance of developments in the field of swarm intelligence and urgent task of deciphering multispectral satellite images.

Particle swarm optimization; multispectral image clustering; K-means; ISODATA.

Классификация изображения – это процесс отнесения пикселей изображения различным группам (классам). Алгоритмы классификации изображений применяются для решения широкого круга проблем, задач, включая сегментацию изображения и цветовую квантизацию [1,2], обнаружение изменений почвенно-растительного покрова для мониторинга и контроля [3], анализ данных [4]. В сфере дистанционного зондирования Земли, целью классификации изображений является «автоматическая категоризация всех пикселей изображения в тематические группы поверхностных покрытий» [5].

В основе классификации мультиспектральных изображений лежит различие значений пикселей, обуславливаемое спектральной отражательной способностью поверхности Земли и спецификами приемного оборудования. Этот тип классификации, базирующийся на спектральной информации, содержащейся в каждом конкретном пикселе, относится к спектральному распознаванию образов. Другими аналогичными типами классификации являются пространственное распознавание образов и временное распознавание образов. Пространственное распознавание образов определяет кластеры по пространственным взаимосвязям между пикселями кластера и пикселями, их окружающими. Временное распознавание образов использует время

в качестве параметра при распознавании изменений поверхности и идентификации покрытий. Данная статья сфокусирована на спектральном распознавании образов.

Существует большое количество алгоритмов неконтролируемой классификации, которые могут быть использованы для получения спектральных классов. Наиболее популярным из них является алгоритм K-means [2]. Альтернативным является алгоритм Iterative Self-Organizing Data Analysis Techniques (ISODATA), который представляет собой модификацию базового алгоритма K-means [5,6]. Алгоритм ISODATA также выполняет роль эталонного алгоритма (бенчмарка) для всех методов неконтролируемой классификации [3].

Целью алгоритма K-means является группировка некоего количества векторов данных в предопределенное количество кластеров. Векторы центров кластеров иницируются произвольным образом. Каждый вектор центра тяжести кластера представляет собой среднее всех векторов, принадлежащих кластеру. Для классификации изображения вектор данных представляет собой пиксел изображения. Далее, каждый пиксел присваивается ближайшему среднему, т.е. центру кластера. После того как все пикселы присвоены ближайшим к ним кластерам, среднее каждого кластера пересчитывается на основе всех векторов, вошедших в кластер. Процесс повторяется до тех пор, пока средние кластеров не перестанут в значительной степени изменяться.

Алгоритм ISODATA является модификацией алгоритма K-means, в котором в качестве метрики подобия используется евклидово расстояние. Пусть:

N_b – количество спектральных каналов мультиспектрального снимка (количество измерений каждого пиксела);

N_p – общее количество всех пикселов изображения;

N_c – количество спектральных классов, которое нужно получить;

$z_p - N_b$ компонент пиксела p ;

m_j – среднее кластера j .

Алгоритм ISODATA может быть представлен следующим образом:

1. Случайным образом проинициализировать N_c средних кластеров.
2. Повтор:
 - а. Для каждого пиксела изображения: произвести присвоение пиксела ближайшему кластеру на основании сравнения со средними всех кластеров, используя евклидово расстояние.
 - б. Пересчитать N_c средних кластеров по формуле

$$m_j = \frac{1}{n_j} \sum_{\forall z_p \in c_j} z_p,$$

где n_j – количество пикселов, принадлежащих кластеру j , C_j – подмножество векторов пикселов кластера j .

До тех пор пока не выполнен критерий останова.

Для оценки качества алгоритма кластеризации используется следующая функция ошибки:

$$J_o = \frac{\sum_j^{N_c} \left[\sum_{\forall z_p \in c_j} d(z_p, m_j) / |c_j| \right]}{N_c},$$

где

$$d(z_p, m_j) = \sqrt{\sum_{k=1}^{N_b} (z_{pk} - m_{jk})^2}.$$

Итеративный характер алгоритмов семейства K-means делает их вычислительно громоздкими. Кроме того, в связи с жадной природой K-means, эти алгоритмы чувствительны к локальным минимумам.

Оптимизаторы роя частиц (particle swarm optimizers, PSO) являются алгоритмами оптимизации, созданными по образу и подобию социального поведения стаи птиц [7]. PSO представляет собой популяционный поисковый процесс, в котором индивиды, представляющиеся как частицы, группируются в рой. Каждая частица в рое представляет собой потенциальное решение оптимизационной проблемы. В PSO каждая частица «пролетает» сквозь многомерное пространство поиска, корректируя свое положение в пространстве поиска в соответствии с собственным опытом и опытом соседних частиц. Таким образом, частица использует собственные лучшие позиции и позиции своих соседей для позиционирования к оптимальному решению. Эффект состоит в том, что частицы «летят» по направлению к минимуму в процессе поиска лучшего решения в широкой области вокруг. Эффективность каждой частицы, т.е. близость частицы к глобальному оптимуму, измеряется с помощью предопределенной функции фитнеса, которая содержит в себе все характеристики задачи оптимизации.

Каждая частица хранит следующую информацию: x_i – текущая позиция частицы; v_i – текущая скорость частицы, y_i – лучшая персональная позиция частицы. Лучшая персональная позиция частицы – это позиция частицы i , в которой значение фитнеса функции для частицы было максимальным на текущий момент времени. Если обозначить f целевую функцию, то личный рекорд частицы в момент времени t вычисляется как

$$y_j(t+1) = \begin{cases} y_i(t) & \text{если } f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1) & \text{если } f(x_i(t+1)) < f(y_i(t)). \end{cases}$$

Существует два основных подхода в оптимизации роя частиц, под названиями *lbest* и *gbest*, отличающиеся топологией соседства, используемой для обмена опытом между частицами. Для модели *gbest* лучшая частица определяется из всего роя. Если позиция лучшей частицы описывается вектором \hat{y} , тогда

$$\hat{y}(t) \in \{y_0, y_1, \dots, y_s\},$$

$$\hat{y}(t) = \min\{f(y_0(t)), f(y_1(t)), \dots, f(y_s(t))\},$$

где s – общее количество частиц в рое.

Для модели *lbest* рой разделяется на перекрывающиеся окрестности частиц. Для каждой окрестности N_j лучшая частица определяется позицией \hat{y}_j . Положение лучшей частицы определяется как лучшая частица в окрестности:

$$N_j = \{y_{i-l+1}(t), y_{i-l+1}(t), \dots, y_{i-1}(t), y_i(t), y_{i+1}(t), \dots, y_{i+l-1}(t), y_{i+l}(t)\},$$

$$\hat{y}_j(t+1) \in N_j | f(\hat{y}_j(t+1)) = \min\{f(y_i(t))\}, \forall y_i \in N_j.$$

Окрестности, как правило, определяются с помощью индексов частиц [8]. Модель *gbest* это частный случай модели *lbest*, в случае, когда $l = s$, т.е. окрестностью является весь рой.

Для каждой итерации алгоритма PSO в модели *gbest* скорость и положение частицы определяется следующим образом:

$$v_i(t+1) = wv_i(t) + c_1r_1(t)(y_i(t) - x_i(t)) + c_2r_2(t)(\hat{y}(t) - x_i(t)), \quad (1)$$

$$x_i(t+1) = x_i(t) + v_i(t+1), \quad (2)$$

где w – вес инерции, c_1 и c_2 – константы ускорения, $r_1(t), r_2(t) \sim U(0,1)$.

Приращение скорости фиксировано, что обеспечивает сходимость. PSO алгоритм выполняет повторение вычислений приращений до тех пор, пока не будет достигнуто заданное число итераций или до тех пор, пока приращения скорости не станут достаточно близки нулю. Качество частиц измеряется фитнес-функцией, которая отражает оптимальность соответствующего решения.

В контексте классификации изображений и, в частности, кластеризации мультиспектрального снимка, отдельная частица представляет N_c средних кластеров. Это означает, что каждая частица x_i представляет собой $x_i = (m_{i1}, \dots, m_{ij}, \dots, m_{iN_c})$, где m_{ij} соответствует вектору центра j -го кластера i -й частицы. Таким образом, рой представляет число потенциальных решений задачи кластеризации изображения. Фитнес-функция, измеряющая качество частиц, представляющих решение задачи кластеризации мультиспектрального снимка, выглядит следующим образом [9]:

$$f(x_i, Z) = w_1 \bar{d}_{\max}(Z, x_i) + w_2 (z_{\max} - d_{\min}(x_i)),$$

где z_{\max} – максимальное значение пиксела в мультиспектральном изображении, Z – матрица принадлежности пикселей кластерам частицы i . Каждый элемент z_{ijp} показывает, принадлежит ли пиксел z_p кластеру c_{ij} частицы i . Константы w_1 и w_2 являются предопределенными. Максимальное среднее евклидово расстояние от частиц до ассоциированных с ними кластеров вычисляется по формуле

$$\bar{d}_{\max}(Z, x_i) = \max_{j=1, \dots, N_c} \left\{ \sum_{\forall z_p \in c_{ij}} d(z_p, m_{ij}) / |c_{ij}| \right\},$$

где $|c_{ij}|$ – мощность множества c_{ij} . Минимальное евклидово расстояние между всеми парами кластеров:

$$d_{\min}(x_i) = \max_{\forall j_1, j_2, j_1 \neq j_2} \{d(m_{ij_1}, m_{ij_2})\}.$$

Приведенная фитнес-функция обеспечивает выполнение одновременно двух оптимизационных подзадач:

- ◆ сведение к минимуму внутренних расстояний между пикселями кластеров и их средними ($\bar{d}_{\max}(Z, x_i)$);
- ◆ сведение к максимуму внешних расстояний между любыми парами кластеров, обеспечиваемое $\bar{d}_{\min}(x_i)$.

Приоритеты между этими целями могут быть определены на этапе инициализации w_1 и w_2 . Классификация изображения с помощью оптимизации роя частиц выглядит следующим образом:

1. Случайным образом проинициализировать N_c средних кластеров для каждой частицы.
2. Цикл от $t=1$ до t_{\max}
 - а. Для каждой частицы

i. Для каждого пикселя изображения z_p :

- ◆ вычислить $d(z_p, m_{ij})$ для всех кластеров c_{ij} ;
- ◆ произвести присвоение пикселя z_p кластеру c_{ij} на основании сравнения:

$$d(z_p, m_{ij}) = \min_{c = 1, \dots, N_{c_1}} \{d(z_p, m_{ic})\}$$

ii. Вычислить фитнесс-функцию $f(x_i(t), Z)$.

b. Найти лучшее глобальное решение

$$\hat{y}(t) = \min\{f(x_1(t), Z), f(x_2(t), Z), \dots, f(x_s(t), Z)\}$$

с. Пересчитать значения центров кластеров с учетом выражений (1) и (2).

Преимуществом применения PSO является то, что во время поиска оптимума выполняется кластеризация. Этот подход уменьшает эффект от начальных условий, по сравнению с ISODATA (особенно для роя относительно большого размера). Согласно исследованиям [9], для обеспечения хорошей сходимости можно использовать следующие значения предопределенных параметров при инициализации: $w_1 = w_2 = 0,5$, $w = 0,72$, $c_1 = c_2 = 1,49$ [9].

Рядом исследований [2, 5, 6, 9, 10, 11] подтверждено, что по сравнению с применением алгоритма ISODATA, использование алгоритма PSO для кластеризации изображений является более эффективным, так как PSO обеспечивает меньшие внутренние расстояния в кластерах и большие внешние расстояния между кластерами.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Scheunders P.* A Genetic C-Means Clustering Algorithm Applied to Image Quantization, *Pattern Recognition*, 30(6), 1997.
2. A Comparison of Clustering Algorithms Applied to Color Image Quantization / *Scheunders P.*, *Pattern Recognition Letters*, Vol 18, 1997. – P. 1379-1384.
3. Unsupervised Robust Change Detection on Multispectral Imagery Using Spectral and Spatial Features / *Wiemker R., Speck A., Kulbach D.*, *Proceedings of the Third International Airborne Remote Sensing Conference and Exhibition, Copenhagen, Denmark. – 1997. – Vol. 1. – P. 640-647.*
4. Data Mining and Knowledge Discovery in Complex Image Data using Artificial Neural Networks / *Evangelou I.E., Hadjimitsis D.G.*, *Workshop on Complex Reasoning on Geographical Data, Cyprus, 2001.*
5. *Remote Sensing and Image Interpretation / Lillesand T., Kiefer R.*, John Wiley & Sons Publishing, 1994.
6. A Viable End-Member Selection Scheme for Spectral Unmixing of Multispectral Satellite Imagery Data / *Saghri J., Tescher A., Omran M.*, *Journal of Imaging Science and Technology. – 2000. – 44 (3). – P. – 196-203.*
7. Particle Swarm Optimization / *Kennedy J., Eberhart R.C.*, *Proceedings of the IEEE International Conference on Neural Networks, Vol 4, Perth, Australia. – 1995. – P. 1942-1948.*
8. Small Worlds and Mega-Minds: Effects of Neighborhood Topology on Particle Swarm Performance / *Kennedy J.*, *Proceedings of the Congress on Evolutionary Computation. – 1999. – P. 1931-1938.*
9. An Analysis of Particle Swarm Optimizers / *Bergh F.*, PhD Thesis, University of Pretoria, South Africa, 2002.
10. Classification Methods for Remotely Sensed Data / *Tso B., P. M.* Mather Taylor & Francis Group, 2009.
11. Study of Different Approach to Clustering Data by Using the Particle Swarm Optimization Algorithm / *Esmin A., Pereira D., Araujo F.*, *IEEE Congress on Evolutionary Computation, 2008.*

Вершовский Евгений Алексеевич

Технологический институт федерального государственного образовательного учреждения высшего профессионального образования «Южный федеральный университет» в г. Таганроге.

E-mail: existenz.sly@gmail.com.

347928, г. Таганрог, пер. Некрасовский, 44.

Тел.: 88634371673.

Vershovsky Evgeniy Alexeevich

Taganrog Institute of Technology – Federal State-Owned Educational Establishment of Higher Vocational Education “Southern Federal University”.

E-mail: existenz.sly@gmail.com.

44, Nekrasovskiy, Taganrog, 347928, Russia.

Phone: +78634371673.

УДК 681.3.062

А.Б. Клевцова

**ПАРАМЕТРИЧЕСКАЯ ЗОННАЯ ОЦЕНКА СОСТОЯНИЯ ТЕХНИЧЕСКОГО
ОБЪЕКТА С ИСПОЛЬЗОВАНИЕМ РЕЖИМНОЙ КАРТЫ**

Предложена методика оценки состояния технического объекта, которая базируется на анализе принадлежности параметра конкретному диапазону значений. При проведении оценки учитывается режимная карта объекта.

Оценка; технический объект; параметр; режимная карта.

A.B. Klevtsova

**PARAMETRICAL BAND MODEL OF THE ESTIMATION CONDITION
FOR TECHNICAL OBJECT WITH USE OF THE REGIME CARD**

The technique of an estimation of a condition for technical object which is based on the analysis of an accessory of parametre to a concrete range of values is offered. At estimation carrying out the regime card of object is considered.

Estimation; technical object; parameter; regime card.

Оценка состояния параметра объекта, значение которого измеряется датчиком, производится путем сравнения его действительного значения с границами нормы. Как только значение превышает норму, то фиксируется нештатная ситуация и реализуются действия, направленные на его нормализацию [1,2].

С точки зрения процедуры оценки измеренные параметры можно разделить на аналоговые и дискретные.

Вся область измерения любого аналогового параметра делится на 3 области их состояния: нормальное, предаварийное и аварийное.

Если значение i -го аналогового параметра m -го объекта удовлетворяет условию $H_{m_i}^j(-) \leq \rho_{m_i} \leq H_{m_i}^j(+)$, то параметр ρ_{m_i} находится в норме или находится в области нормального состояния.

Обозначим $H_{m_i}^j(-)$, $H_{m_i}^j(+)$ – нижние и верхние границы зоны нормального изменения параметра ρ_{m_i} для j -го режима функционирования m -го объекта.