

Кластеризация пикселей многозональных снимков земной поверхности с использованием нейронной сети

Н.Ю. Севастьянова¹, О.Ю. Иванов¹

¹Уральский федеральный университет, Мира 19, Екатеринбург, Россия, 620002

Аннотация

В настоящей работе предложен алгоритм кластеризации, для использования при обработке данных дистанционного зондирования Земли. Неотъемлемой частью алгоритма является самоорганизующаяся сеть конкурентного типа. Проведено исследование алгоритма. Представлены примеры обработки реальных космических снимков и предложены рекомендации по использованию алгоритма.

Ключевые слова

Дистанционное зондирование Земли, кластеризация, нейронная сеть

1. Введение

Данные дистанционного зондирования Земли (ДЗЗ) широко используются в различных отраслях народнохозяйственной деятельности. Это стало возможным благодаря успешной эксплуатации множества орбитальных систем космического мониторинга, которые позволяют получать качественные снимки в различных частотных диапазонах [1]. Однако в «сыром» виде снимки не представляют практического интереса. Чтобы воспользоваться данными космической съемки, необходимо провести их предварительную обработку [1, 2].

2. Основная часть

Одной из задач обработки космической информации является автономная классификация (или кластеризация) объектов изображения [2]. При обработке данных ДЗЗ объектом классификации является, как правило, пиксель изображения, а признаком, по которому осуществляется кластеризация, – яркость (или вектор яркости для многозональных снимков). Основным методом, используемым в наиболее известных программных продуктах по обработке данных ДЗЗ, таких как *ENVI*, *ScanExIP* и др., является итеративный самоорганизующийся метод анализа данных *ISODATA*. К его недостаткам следует отнести то, что кластеризация занимает много времени и не позволяет контролировать вероятность ошибки в процессе обработки [3].

В работе предлагается алгоритм кластеризации на основе самоорганизующейся сети конкурентного типа [4], который позволяет уменьшить отмеченные недостатки. Для обучения сети создается массив входных векторов \vec{x} , количество которых определяется числом пикселей изображения. Размерность вектора зависит от количества спектральных каналов. Нормализация входных данных $\vec{x}'_i = \vec{x}_i / \sqrt{\sum_{i=1}^n \vec{x}_i^2}$ более равномерно распределяет нейроны в пространстве обучающих векторов [5]. Уменьшения количества «мертвых» нейронов можно добиться равномерной инициализацией вектора \vec{w} , который образуют веса синаптических связей нейронов. При активации сети вектором \vec{x} , в конкурентной борьбе побеждает тот нейрон, веса которого в наименьшей степени отличаются от соответствующих компонентов этого вектора $d(\vec{x}, \vec{w}_j) = \min_{1 \leq i \leq N} d(\vec{x}, \vec{w}_i)$, где $d(\vec{x}, \vec{w})$ – обозначает расстояние (в выбранной метрике) между соответствующими векторами.

Результаты исследования влияния параметров алгоритма на его качественные и скоростные характеристики показали, что выбор типа метрики не оказывает существенного влияния на качество самоорганизации, число нейронов определяется количеством тематических классов

(но при этом может быть уменьшено в ходе обучения сети), одним из наиболее быстрых алгоритмов обучения сети с самоорганизацией конкурентного типа (Кохонена) является алгоритм нейронного газа [4]. Чтобы увеличить скорость самоорганизации, параметры алгоритма необходимо уменьшать с каждым циклом обучения. Рекомендуемые значения коэффициента скорости обучения: максимальное значение – 0.99, минимальное значение – 0.01. Для уровня соседства рекомендуемое начальное значение – 2.0, конечное – 0.04.

На рисунке 1 представлен сравнительный результат обработки снимка предложенным алгоритмом и алгоритмом *ISODATA* с аналогичными параметрами.

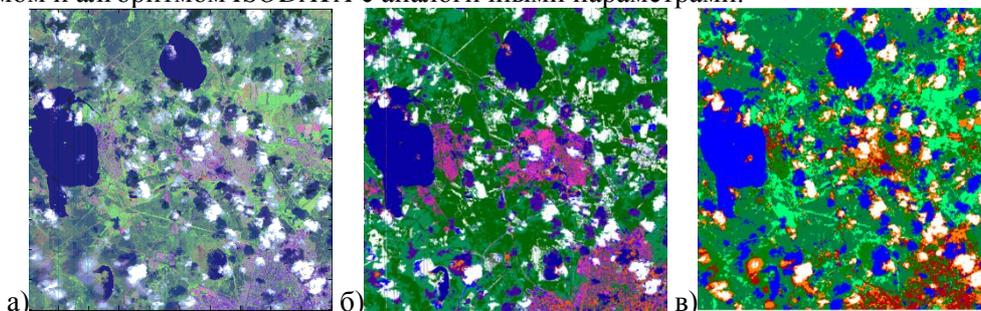


Рисунок 1: Обработка снимка космического аппарата *SPOT*: а) исходный снимок, б) нейросетевой алгоритм, в) алгоритм *ISODATA*

Из рисунка видно, что предложенный алгоритм лучше распознает тени от облаков, *ISODATA* относит пиксели этого кластера к водной поверхности. Также нейронная сеть позволяет более четко выделить дороги и просеки. Остальные объекты (городская застройка, облака, вода и др.) классифицированы идентично. Кроме того, алгоритм за счет объединения нейронов (радиус сходимости – 0.1) сформировал единый класс «лесной массив».

3. Заключение

Разработан алгоритм кластеризации пикселей многозонального изображения, базирующийся на нейронной сети Кохонена. Алгоритм показал высокое качество обработки реальных данных в сравнении с алгоритмом *ISODATA*. Проведенное исследование позволило сформулировать рекомендации по выбору параметров алгоритма.

4. Благодарности

Работа было поддержана РФФИ, контракт № 19-29-09022.

5. Литература

- [1] Шовенгердт, Р.А. дистанционное зондирование. Модели и методы обработки изображений / Р.А. Шовенгердт. – М.: Техносфера, 2013. – 592 с.
- [2] Антонов, И.К. Воздушная разведка. Автоматизированное дешифрование радиолокационных изображений / И.К. Антонов, А.Н. Детков, Д.А. Ницак. – М.: Радиотехника, 2021. – 296 с.
- [3] Labunets, V.G. Clifford Algebras as Unified Language for Multicolor Image Processing and Pattern Recognition / V.G. Labunets // Computational Noncommutative Algebra and Applications. NATO Science Series. – London: Kluwer Academic Publishers, 2003. – P. 197-226.
- [4] Осовский, С. Нейронные сети для обработки информации / С. Осовский. – М.: Финансы и статистика, 2004. – 300 с.
- [5] Myasnikov, F.S. Preclassification of remote monitoring data in change detection tasks / F.S. Myasnikov, O.Y. Ivanov // AIP Conference Proceedings, International Conference on Numerical Analysis and Applied Mathematics. – 2020. – Vol. 2293 – P. 140007.