

Применение самоорганизующейся карты Кохонена для сегментации гиперспектральных изображений*

М.Н. Гурьева

mariag221115@gmail.com

Рязанский государственный радиотехнический университет, Рязань, Россия

Настоящая работа посвящена задаче сегментации гиперспектральных изображений. Предложенный алгоритм решения задачи и программное обеспечение, реализующее его, обеспечивают надежную идентификацию однородных по содержанию областей (водная поверхность, антропогенные объекты, растительность и т.д.) на гиперспектральных космических снимках, полученных с космического аппарата дистанционного зондирования Земли «Ресурс-П».

Ключевые слова: дистанционное зондирование Земли, сегментация, гиперспектральные изображения, карта Кохонена, нейронные сети

The Kohonen self-organizing maps application for segmentation of hyperspectral images*

M.N. Guryeva

Ryazan state radio engineering university, Ryazan, Russia

This paper is devoted to the task of hyperspectral images segmentation. The proposed algorithm and software that implements it provides reliable identification of homogeneous regions in the hyperspectral satellite images obtained from the satellite of Earth remote sensing "Resurs-P".

Keywords: hyperspectral imaging, remote sensing, segmentation, Kohonen map

Введение

Гиперспектральные изображения являются относительно новым достижением в дистанционном зондировании Земли и представляют собой трехмерный массив данных, который включает в себя пространственную информацию об объекте, дополненную спектральной информацией по каждой пространственной координате. Для получения таких изображений используется оптоэлектронная система, позволяющая одновременно производить замеры интенсивности солнечного освещения на большом числе длин волн. С использованием спектральной характеристики каждого пикселя, можно дистанционно идентифицировать множество материалов.

При обработке информации, поступающей со спутника, важным этапом является сегментация, предназначенная для выделения областей с однородными объектами, непохожими друг на друга, например, таких как водная поверхность, растительность, песок, снег, антропогенная зона и др. Это облегчает реализацию дальнейшего, более детального анализа изображения.

Алгоритм сегментации

Высокое разрешение космических снимков, а также большая размерность входных данных требует автоматизации процесса сегментации изображе-

ния. В настоящей работе рассмотрено использование самоорганизующейся карты Кохонена, представляющей собой однослойную нейронную сеть с обучением без учителя, которая является методом проецирования многомерного пространства в пространство с более низкой размерностью, в данном случае, двумерное. Преимуществами этого метода являются устойчивость к зашумленным данным, быстрое и неуправляемое обучение, а также возможность упрощения многомерных входных данных с помощью визуализации. В процессе работы сети происходит вычисление общих признаков внутри большой входной выборки. Результатом работы является кластеризация данных. Представляя входную последовательность сети как набор спектральных характеристик каждой пространственной координаты, можно выявить зависимость и оценить принадлежность этого пикселя к тому или иному классу.

Обучение сети

Первым этапом алгоритма является обучение сети. На этом шаге происходит автоматическое формирование усредненных значений спектральных характеристик каждого класса, для последующего использования их в качестве эталонных при построении карты. Количество классов на изображении определяется автоматически, в процессе обучения сети.

Формирование весовых векторов На первом этапе каждая эталонная характеристика представляет собой нормализованный вектор, заполненный

Работа опубликована при финансовой поддержке РФФИ, грант 15-07-20347.

случайными числами. После корректировки это будет отражать усредненную спектральную характеристику каждого класса.

Формирование входной последовательности для обучения Входная последовательность выбирается как набор спектральных характеристик пикселей, равномерно распределенных по изображению.

Определение принадлежности к тому или иному классу Определяется мера соответствия, в качестве которой выбрано Евклидово расстояние текущей спектральной характеристики до всех весовых векторов. Вектор, расстояние до которого минимально, признается «победителем». Изначально количество классов выбрано достаточно большим.

Корректировка весовых векторов Весовые векторы корректируются следующим образом: $m(t) = m(t-1) + h_c(t) * (x(t) - m(t-1))$, где $m(t)$ - скорректированный весовой вектор, $m(t-1)$ - нескорректированный весовой вектор, $x(t)$ - спектральная характеристика текущего пикселя $h_c(t) = \alpha(t) * \delta(t)$ - корректировочная функция. Корректировочная функция $h_c(t)$ определяется двумя коэффициентами: скоростью обучения $\alpha(t)$ и функцией соседства $\delta(t)$. Скорость обучения отвечает за точность подстройки и на начальном этапе $\alpha(t) = 0.7$. В процессе обучения сети этот коэффициент падает по экспоненциальной зависимости и к концу обучения достигает минимального значения. Это означает, что на первых итерациях алгоритма происходит жесткая корректировка весовых векторов, а на последних - «подстройка», что приводит к формированию усредненной спектральной характеристики каждого класса. В качестве функции соседства выбрана Гауссовская функция $\delta(t) = e^k, k = -S^2 / (2 * \sigma^2(t))$, где S^2 - расстояние на карте между текущим весовым вектором и «победителем», $\sigma(t)$ - множитель, уменьшающий количество соседей с итерациями, монотонно убывает.

Окончание обучения Обучение считается законченным, когда минимизируется относительная ошибка карты.

Оптимизация количества классов Перед переходом к следующему этапу производится автоматический анализ изначально большого числа классов для объединения наиболее схожих из них.

Построение карты

По окончании обучения каждому пикселю изображения на основе вычисления меры сходства спектральной характеристики с откорректированными весовыми векторами присваивается номер класса. По полученным данным формируется карта и

RGB-модель исходных данных, которые затем совмещаются для лучшего визуального восприятия. Таким образом, в результате карта Кохонена классифицирует входные данные на кластеры и визуально отображает многомерные входные данные в двумерной плоскости, распределяя векторы близких признаков в соседние ячейки и раскрашивая их в зависимости от анализируемых параметров

Экспериментальные исследования

Для проведения экспериментальных исследований было разработано программное обеспечение на языке C++. Исходные данные представляют собой гиперспектральное изображение, состоящее из 130 каналов, снятых в диапазоне длин волн 395–998 нм, полученное с космического аппарата Ресурс-П. На Рис.1 представлены:

RGB-модель исходных данных (а),
карта Кохонена (б),
сегментация алгоритмом k-средних (в).

В результате построения карты было автоматически определено 8 классов объектов на изображении. По результатам обработки можно заметить, что успешно выполнено определение водной поверхности, растительности, антропогенных объектов. По сравнению с алгоритмом k-средних достигнута более высокая производительность и низкая ошибка карты.




Рис. 1: а) RGB-модель исходных данных; б) карта Кохонена; в) результат обработки алгоритмом k -средних

Выводы

В данной работе был предложен алгоритм сегментации гиперспектрального изображения с использованием самоорганизующейся карты Кохонена. По сравнению с популярным алгоритмом k -средних значительно повышена производительность, а также снижена ошибка обнаружения. Анализ результатов компьютерных экспериментов позволяет говорить об успешной работе созданного алгоритма и программного обеспечения.