

Применение автоэнкодеров для сжатия гиперспектральных данных

А.С. Минкин¹

¹Национальный исследовательский центр «Курчатовский институт», пл. Академика Курчатова, 1, Москва, Россия, 123182

Аннотация

Предложена методика нейросетевого сжатия гиперспектральных данных с помощью автоэнкодеров. Проведено сравнение степени сжатия с помощью трех различных вариантов автоэнкодеров с методом главных компонент. Выполнено тестирование алгоритмов сжатия на гиперспектральных данных сенсора AVIRIS, представлен график зависимости величины меры различия от степени сжатия исходных данных.

Ключевые слова

Нейронные сети, автоэнкодеры, сжатие данных

1. Введение

В последние годы сжатие спутниковых изображений, особенно гиперспектральных, является актуальной задачей в связи с ограниченной скоростью передачи информации со спутников. Большой объем данных в сочетании с корреляциями по соседним спектральным линиям [1,2] в гиперспектральных изображениях позволяет использовать различные методы снижения размерности для получения высокой степени сжатия с потерями при сохранении малого значения меры различия исходного и восстановленного сигнала.

Одним из способов понижения размерности анализируемого векторного пространства является применение автоэнкодеров [3] - специальных архитектур нейронных сетей, позволяющих снижать размерность входных данных с целью сжатия изображений и последующей классификации и кластеризации данных [4]. Обучение автоэнкодера сводится к подгонке синаптических весов, вызывающих отклик сети, равный входному изображению с точностью до заданного значения ошибки. В данной работе рассматриваются архитектуры автоэнкодеров, в которых количество нейронов скрытого слоя меньше размерности входных данных. Представлен алгоритм сжатия с потерями на основе нескольких вариантов сжимающих автоэнкодеров для работы с отдельными спектральными пикселями. Сделана оценка степени сжатия в зависимости от ошибки восстановления по данным сенсора AVIRIS на примере набора данных (KSC) [5]. Проанализирована эффективность сжатия гиперспектральных изображений с помощью однослойного, многослойного и сверточного автоэнкодеров в сравнении с методом главных компонент.

2. Постановка задачи и численные результаты

Целью данной работы является исследование возможностей автоэнкодеров для сжатия гиперспектральных спутниковых снимков на примере данных Kennedy Space Center без учёта спектральных каналов, соответствующих сильному поглощению света в водяном паре.

Пусть исходный снимок представлен матрицей, состоящей из N пространственных пикселей, каждому из которых отвечает L спектральных каналов. В этом случае эффективность сжатия можно оценить, например, с помощью меры различия, вычисляемой по формуле

$$E = \sum_{n=1}^N \sum_{l=1, x_{n,l}>0}^L |1 - x'_{n,l}/x_{n,l}| \quad (1)$$

На рисунке 1 представлен график зависимости метрики (1) от степени сжатия для однослойного (A1), многослойного (A2) и сверточного (A3) автоэнкодера в сравнении с методом главных компонент, а также график зависимости ошибки обучения сети (средний квадрат отклонения восстановленных данных от исходных) от степени сжатия.

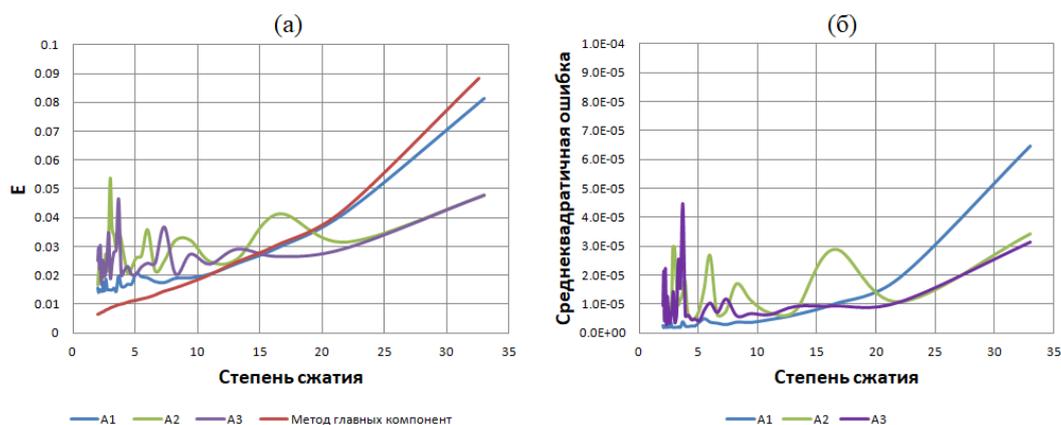


Рисунок 1: Мера различия сигналов (а) и ошибка обучения автоэнкодеров (б) в зависимости от степени сжатия исходного изображения

3. Заключение

В данной работе реализована методика попиксельного сжатия гиперспектральных изображений с помощью автоэнкодеров и сделано её сравнение с методом главных компонент. По степени сжатия однослойный автоэнкодер и метод главных компонент эквивалентны. При небольшой степени сжатия использование метода главных компонент предпочтительно, так как демонстрирует более стабильный и точный результат. В отличие от метода главных компонент, автоэнкодеры требуют обучения и настройки весов сети. При этом эффективность их применения находится в прямой зависимости от конечного значения ошибки обучения нейронной сети, которая имеет тенденцию к осцилляциям при выборе более сложных моделей автоэнкодеров. Однако, при высоких значениях степени сжатия многослойный и сверточный автоэнкодеры демонстрируют значительное преимущество по сравнению с методом главных компонент, а результат обучения оказывается более устойчивым при выборе меньшего числа нейронов в латентной области, что оказывается более эффективным для дальнейшей кластеризации неразмеченных данных.

4. Литература

- [1] Windrim, L. Unsupervised feature-learning for hyperspectral data with autoencoders / L. Windrim, R. Ramakrishnan, A. Melkumyan, R.J. Murphy, A. Chlingaryan. – Remote Sensing. – 2019. – Vol. 11(7). – P. 864
- [2] Zamyatin, A.V. An algorithm for compressing hyperspectral aerospace images with the account of interband correlation / A.V. Zamyatin, A.Zh. Sarinova // Applied Informatics. – 2013. – Vol. 47(5). – P. 35-42.
- [3] Hinton, G.E. Reducing the dimensionality of data with neural networks / G.E. Hinton, R.R. Salakhutdinov. – Science. – 2006. – Vol. 313. – P. 504-507.
- [4] Mou, L. Unsupervised spectral-spatial feature learning via deep residual Conv-Deconv network for hyperspectral image classification / L. Mou, P. Ghamisi, X.X. Zhu // IEEE Trans. Geosci. Remote Sens. – 2018. – Vol. 56(1). – P. 391-406.
- [5] Наборы данных с размеченными гиперспектральными изображениями [Электронный ресурс] – Режим доступа: http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes.