

Обобщение основанного на машинном обучении метода компрессии на гиперспектральные изображения

А.И. Максимов

Самарский национальный исследовательский университет
им. академика С.П. Королева
Самара, Россия
aleksei.maksimov.ssau@gmail.com

М.В. Гашников

Самарский национальный исследовательский университет
им. академика С.П. Королева
Самара, Россия
mih-fastt@yandex.ru

Аннотация—Статья имеет дело с задачей обобщения основанных на машинном обучении двумерных фреймворков компрессии на гиперспектральные данные. Количество компонент в этих данных обычно настолько велико, что мы можем рассматривать эти данные как трёхмерные массивы с полноценным третьим измерением. Однако архитектура основанных на машинном обучении фреймворков компрессии обычно существенным образом опирается на двумерность исходных данных. Поэтому задача обобщения основанных на машинном обучении фреймворков компрессии на гиперспектральные данные является нетривиальной и актуальной. Большинство компонент в таких данных обычно очень похожи друг на друга. Мы используем сильную похожесть этих компонент для обобщения основанных на машинном обучении фреймворков компрессии на гиперспектральные данные. Мы проводим вычислительные эксперименты по исследованию эффективности предложенного подхода к обобщению основанных на машинном обучении фреймворков компрессии на гиперспектральные данные. Экспериментальные результаты доказывают, что использование предложенного подхода позволяет существенно увеличить эффективность компрессии гиперспектральных данных.

Ключевые слова— гиперспектральные данные, машинное обучение, компрессия, обобщение, отклонение.

1. ВВЕДЕНИЕ

Сфера применения гиперспектральных изображений, в том числе данных дистанционного зондирования, постоянно расширяется. В этих условиях актуальной является задача обобщения основанных на машинном обучении (МО) методов компрессии на гиперспектральные изображения.

Основной спецификой гиперспектральных изображений [1, 2], безусловно, является высокая спектральная размерность, так как количество спектральных компонент может достигать нескольких сотен. Кроме того, динамические характеристики спектральных компонент значительно различаются, значительная часть этих компонент обычно сильно коррелирована, а остальные компоненты при этом зачастую зашумлены. Все эти факторы затрудняют как сжатие самих спектральных компонент [3-5], так и использование взаимосвязей между ними.

Перспективным решением (см. рис. 1) обозначенной проблемы, как на этапе компрессии спектральных компонент, так и на этапе использования межкомпонентных корреляций для повышения коэффициента сжатия, являются алгоритмы машинного

обучения, потенциал использования которых в области компрессии изображения ещё не полностью раскрыт в настоящее время.

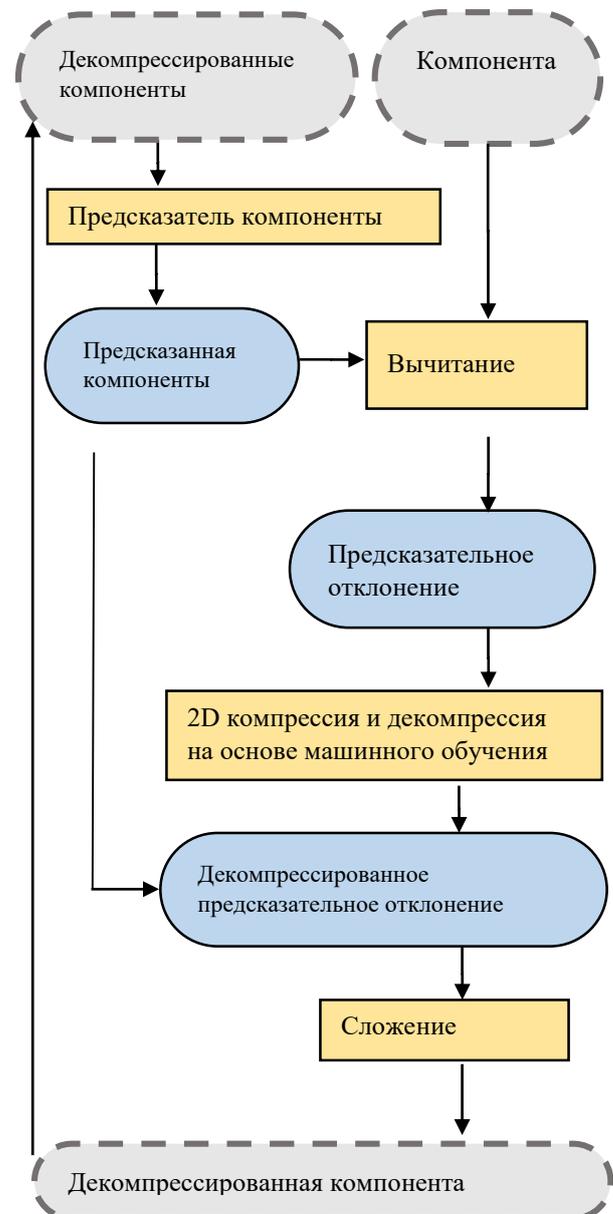


Рис. 1. Предсказатель компонент для компрессии гиперспектральных данных

В данной работе выполняется адаптация нейросетевых методов компрессии на случай гиперспектральных

изображений за счёт использования высокой корреляции между спектральными компонентами.

2. ОБОБЩЕНИЕ МЕТОДА КОМПРЕССИИ НА ГИПЕРСПЕКТРАЛЬНЫЕ ИЗОБРАЖЕНИЯ

Предлагаемый подход к обобщению основанных на МО методов компрессии на гиперспектральные изображения проиллюстрирован на рис. 1.

В этой статье мы исследуем задачу обобщения основанных на машинном обучении двумерных фреймворков компрессии на гиперспектральные данные. Количество компонент в этих данных обычно настолько велико, что мы можем рассматривать гиперспектральные данные как трёхмерные массивы с полноценным третьим измерением.

Однако архитектура основанных на машинном обучении фреймворков компрессии обычно существенным образом опирается на двумерность исходных данных. Поэтому задача обобщения основанных на машинном обучении фреймворков компрессии на гиперспектральные данные является нетривиальной и актуальной.

Большинство компонент в гиперспектральных данных обычно очень похожи друг на друга. Мы используем сильную похожесть компонент для обобщения основанных на машинном обучении фреймворков компрессии на гиперспектральные данные. Мы разрабатываем эффективный предсказатель гиперспектральных этажей, который позволяет нам компрессировать предсказательное отклонение вместо исходной компоненты.

Разброс значений этого предсказательного отклонения гораздо меньше, чем разброс значений исходной компоненты, поэтому степень компрессии предсказательного отклонения гораздо больше, чем степень компрессии исходной компоненты. Такой подход позволяет нам обобщить основанные на машинном обучении фреймворки компрессии на гиперспектральные данные.

3. ВЫЧИСЛИТЕЛЬНЫЕ ЭКСПЕРИМЕНТЫ

Проведены вычислительные эксперименты по использованию высокой межкомпонентной корреляции гиперспектральных изображений для повышения эффективности методов компрессии (см. рис. 2).

Использование межкомпонентной корреляции выполнялось за счёт использования специализированного аппроксимационного алгоритма, осуществляющего переход к разностному представлению компонент, основанному на вычислении постаппроксимационных остатков, возникающих при аппроксимации спектральных компонент.

Вычислительные эксперименты на реальных гиперспектральных данных дистанционного зондирования показали, что указанный аппроксимационный алгоритм позволяет существенно улучшить коэффициент компрессии, что позволяет сделать вывод о его эффективности при решении задачи обобщения нейросетевых методов компрессии на гиперспектральные изображения.

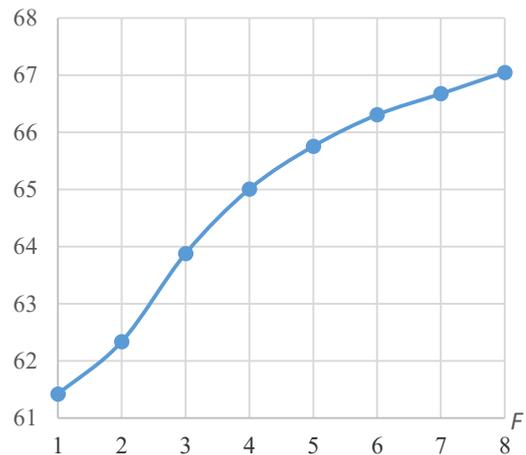


Рис. 2. Усредненный процентный выигрыш при компрессии натуральных гиперспектральных данных, полученный благодаря использованию предсказателя гиперспектральных компонент (F – количество опорных компонент предсказателя)

4. ЗАКЛЮЧЕНИЕ

Основанные на МО двумерные фреймворки компрессии обобщены на гиперспектральные данные. Для обобщения использована сильная похожесть спектральных компонент. Экспериментальные результаты доказали, что использование предложенного подхода позволяет существенно увеличить эффективность компрессии гиперспектральных данных. Следовательно, применение предсказателя компонент является перспективным подходом к обобщению основанных на машинном обучении фреймворков компрессии на гиперспектральные данные.

БЛАГОДАРНОСТИ

Исследование выполнено за счет гранта Российского научного фонда (проект 22-21-00662).

ЛИТЕРАТУРА

- [1] Бурдуковский, С.О. Обзор литературы по методам машинного обучения при обработке изображений / С.О. Бурдуковский // Приоритетные направления инновационной деятельности в промышленности. – 2021. – С. 154-155.
- [2] Фирсов, Н.А. Нейросетевая классификация гиперспектральных изображений растительности с формированием обучающей выборки на основе адаптивного вегетационного индекса / Н.А. Фирсов, В.В. Подлипов, Н.А. Ивлиев, П.П. Николаев, С.В. Машков, П.А. Ишкин, Р.В. Скиданов, А.В. Никоноров // Компьютерная оптика. – 2021. – Т. 45, № 6. – С. 887-896. DOI: 10.18287/2412-6179-CO-1038.
- [3] Кузьмина, М.Г. Многослойные сети-автоэнкодеры в задачах анализа и обработки гиперспектральных изображений / М.Г. Кузьмина // Препринты Института прикладной математики им. М.В. Келдыша РАН. – 2021. – С. 28-21.
- [4] Васин, Д.Ю. Регулярные методы кодирования растровых изображений дистанционного зондирования Земли / Д.Ю. Васин // Графикон-конференция по компьютерной графике и зрению. – 2019. – Т. 29. – С. 152-158.
- [5] Минкин, А.С. Сжатие гиперспектральных данных методом главных компонент / А.С. Минкин, О.В. Николаева, А.А. Руссков // Компьютерная оптика. – 2021. – Т. 45, № 2. – С. 235-244. DOI: 10.18287/2412-6179-CO-806.