



ностям длин векторов смещения. Результаты экспериментов свидетельствует о возможности использования максимальной невязки в качестве единой оценки аномальности поведения в простых и сложных сценах.

### Литература

1. Sodemann, A. A Review of Anomaly Detection in Automated Surveillance / A. Sodemann, M. Ross, B. Borghetti // IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews. – 2012. – Vol. 42(6). – P. 1257-1272.
2. Chandola, V. Anomaly detection: A survey / V. Chandola, A. Banerjee, V. Kumar // ACM Computing Surveys (CSUR), 2009, V. 41(3), 72 p.
3. Jolliffe, I. Principal Component Analysis, Series: Springer Series in Statistics / I. Jolliffe // NY: Springer, 2002, 488 p.
4. Шаталин, Р.А. Обнаружение нехарактерного поведения в задачах видеонаблюдения / Р.А. Шаталин, В.Р. Фидельман, П.Е. Овчинников // Компьютерная оптика. – 2017. – Т. 41, № 1. – С. 37-45.
5. Maddalena L. A Self-Organizing Approach to Background Subtraction for Visual Surveillance Application / L. Maddalena, A. Petrosino // IEEE Transactions on Image Processing, 2008, V. 17(7), P. 1168-1177.
6. Шаталин, Р.А. Критерий качества выделения фона с использованием морфологических операторов для задач обнаружения нештатных ситуаций / Р.А. Шаталин, П.Е. Овчинников // Системы управления и информационные технологии, 2014, Т. 56(2), С. 190-194.
7. Antonakaki, P. Detecting Abnormal Human behavior using Multiple Cameras / P. Antonakaki, D. Kosmopoulos, S. Perantonis // Signal Processing, 2009, V. 89(9), P. 1723-1738.
8. Mahadevan, V. Anomaly Detection and Localization in Crowded Scenes / V. Mahadevan, W. Li, V. Bhalodia, N. Vasconcelos // IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, V. 36(1), P. 18-31.

Р.Р. Юзькив

### КЛАСТЕРИЗАЦИЯ ГИПЕРСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ ДЛЯ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ СЖАТИЯ МЕТОДОМ КОДИРОВАНИЯ С ПРЕОБРАЗОВАНИЕМ

(Самарский университет)

На рисунке 1а приведена классическая базовая схема сжатия гиперспектральных изображений (ГСИ) на основе блочного кодирования с преобразованием [1-3]. На первом этапе данные разбиваются на непересекающиеся трёхмерные блоки одинакового размера  $b_i$ ,  $0 \leq i < K$ , где  $K$  – количество получившихся блоков. На втором этапе с помощью дискретного косинусного преобразования (ДКП) для каждого блока вычисляется его спектр  $B_i$ . На третьем этапе происходит квантование и округление значений спектра для получения кванто-



ванных коэффициентов  $C_i$ . На четвёртом этапе происходит статистическое кодирование. При этом спектральные значения с нулевыми координатами в блоке (низкочастотные DC-коэффициенты), отвечающие за средние значения, как правило, сильно отличаются от остальных значений (получивших название высокочастотных AC-коэффициентов).

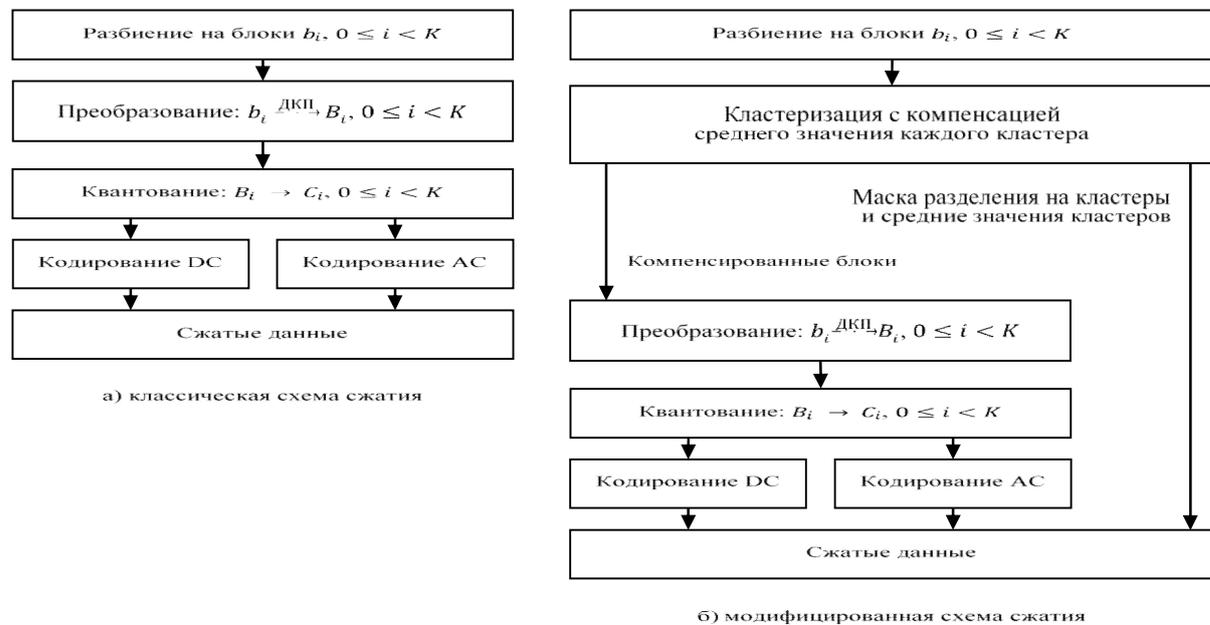


Рисунок 1 – Классическая и модифицированная схемы сжатия гиперспектральных изображений на основе кодирования с преобразованием

Использование ДКП обусловлено следующими причинами. Во-первых, для сигналов с экспоненциальной автокорреляционной функцией (АКФ) ДКП хорошо аппроксимирует преобразование Кархунена-Лоэва, которое является оптимальным с точки зрения концентрации энергии сигнала в наименьшем количестве спектральных отсчётов [4]. Во-вторых, имеются быстрые алгоритмы вычисления ДКП [5].

Однако в работе [6] было показано, что космические ГСИ по пространственным координатам намного лучше описываются двухэкспоненциальной АКФ, чем обычной экспоненциальной. Предложенная двухэкспоненциальная модель соответствует двумасштабному представлению изображения [7] в виде суммы двух составляющих – низкочастотной (описывающей протяжённые кусочно-постоянные области) и высокочастотной (описывающей текстурную компоненту).

Поэтому в данной работе предлагается модифицированная схема сжатия (рисунок 1б), суть которой заключается в удалении низкочастотной составляющей изображения до этапа преобразования. Такое удаление соответствует приведению двумасштабного изображения к одномасштабному, что должно увеличить эффективность применяемого ДКП.



Удаление низкочастотной составляющей предлагается проводить с помощью дополнительного этапа кластеризации ГСИ по пространственным координатам, на котором выполняются следующие действия.

1. Так как кластеризация по всем каналам ГСИ размера  $N_1 \times N_2 \times N_3$  может являться вычислительно трудоёмкой задачей, то каналы прореживаются следующим образом. Во-первых, из каждых  $M$  последовательных каналов, где  $M$  – размер блока преобразования вдоль спектральной координаты, выбирается один с максимальной дисперсией. Из оставшихся каналов выбирается  $p$  каналов с максимальной дисперсией, где  $p$  – параметр алгоритма.
2. Для полученного прореженного ГСИ проводится кластеризация методом  $k$ -средних [8]. В качестве начальных значений центров кластеров используется детерминированная версия алгоритма на основе работы [9], которая выглядит следующим образом.
  - 2.1. В качестве первого центра кластера берётся некоторая фиксированная точка изображения – например, с координатами  $(0, 0)$ .
  - 2.2. Для каждой точки находится расстояние до ближайшего центра из тех, что уже выбраны. В качестве следующего центра выбирается точка с максимальным расстоянием до ближайшего центра.
  - 2.3. Шаги 2.2 и 2.3 повторяются до тех пор, пока не будет найдено заданное количество центров  $q$ , где  $q$  – параметр алгоритма.
3. На основе построенных кластеров строится маска разделения изображения на кластеры, где каждому пространственному отсчёту ставится в соответствие индекс кластера (значение от 0 до  $q - 1$ ) и для каждого кластера вычисляется вектор средних значений уже по всем каналам ГСИ (т. е. вектора будут иметь размер  $N_3$ ).
4. Из каждого отсчёта изображения вычитается соответствующее среднее значение кластера.
5. В поток выходных данных записываются маска разделения ГСИ на кластеры и векторы средних значений. Векторы средних значений статистически кодируются таким же способом, как и DC-коэффициенты (см., например, стандарт JPEG [10]).

Экспериментальные исследования проводились на 12 участках ГСИ размера  $512 \times 512 \times 224$  (рисунок 2), полученных сканером Aviris и находящихся в открытом доступе [11].

Результаты были проверены на двух алгоритмах, различающихся по способу вычисления коэффициентов квантования.

1. Алгоритм А на основе упрощённого алгоритма [2] (использовались фиксированные значения параметров  $Q = 80$  и  $k = 1,5$ ). В качестве развёртки AC-коэффициентов в одномерный массив использовался алгоритм на основе количества квантованных коэффициентов, равных нулю [12].

2. Алгоритм Б на основе работы [12] (базовый алгоритм, использовалось значение заданной среднеквадратической ошибки  $\sigma = 0,5$ ).

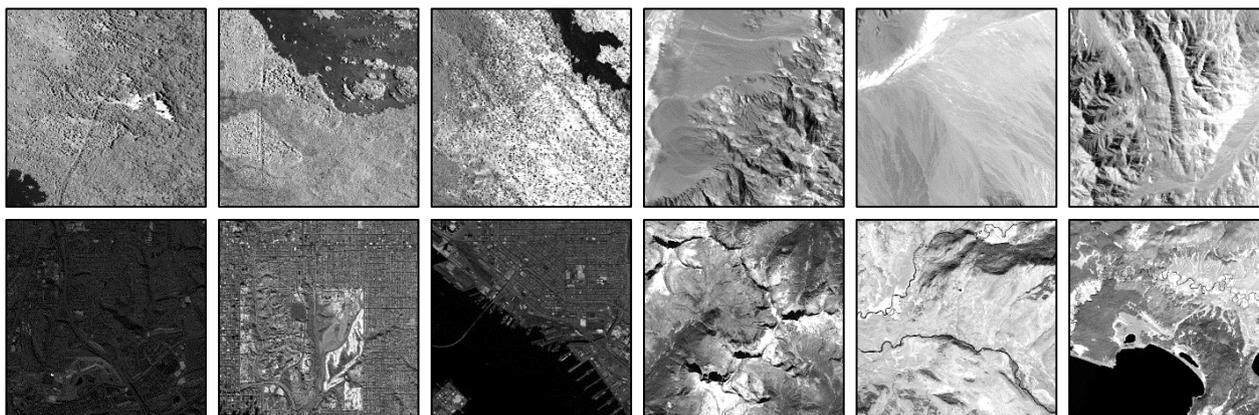


Рисунок 2 – Тестовой набор участков ГСИ (64-ый канал)

На рисунке 3 приведены усреднённые по всем ГСИ графики процентного уменьшения объёма сжатых данных относительно классической схемы при различных значениях  $p$  количества каналов, по которым строится кластеризация и различных значениях  $q$  количества кластеров.

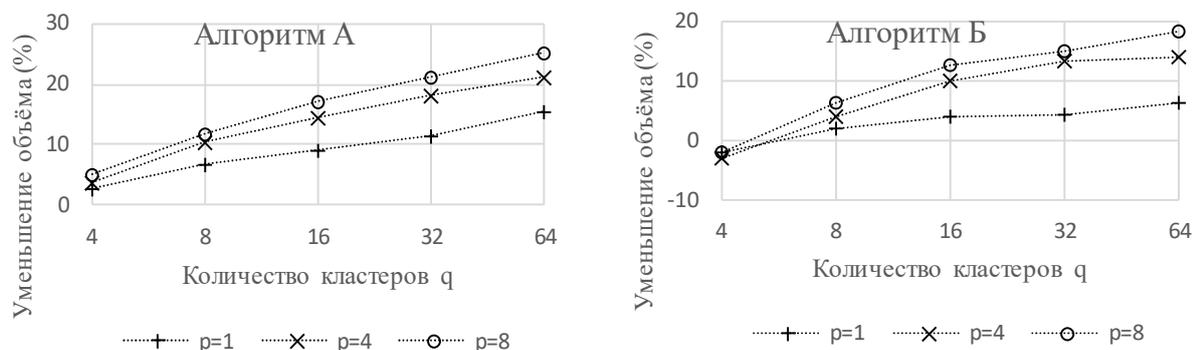


Рисунок 3 – Процентное уменьшения объёма сжатых данных по сравнению с классической схемой сжатия

Видно, что добавление к закодированной информации дополнительного объёма данных в виде маски разделения ГСИ на кластеры и векторов средних значений не только компенсируется уменьшением объёма основных данных (в виде DC и AC-коэффициентов), но и приводит к уменьшению итогового объёма сжатых данных. Например, при количестве кластеров 32 среднее уменьшение может составить от 10 до 20 % для алгоритма А, от 5 до 15 % для алгоритма Б (в зависимости от количества каналов, по которым строится кластеризация).

### Литература

1. Karami A. Hyperspectral image compression using 3D discrete cosine transform and support vector machine learning / A. Karami, S. Beheshti, M. Yazdi // Proceedings of Information Science, Signal Processing and their Applications (ISSPA). – 2012. – P. 826-829.
2. Qiao T. Effective compression of hyperspectral imagery using an improved 3D DCT approach for land-cover analysis in remote-sensing applications / T. Qiao, J.



Ren, M. Sun, J. Zheng, S. Marshall // International Journal of Remote Sensing. – 2014. – Vol. 35(20). – P. 7316–7337.

3. Mankar P. R. Image compression based on 3D-DCT / P. R. Mankar, S. S. Rane, A. E. Patil // International Journal of Research in Science & Engineering. – 2017. – Vol. 3(2). – P. 16-22.

4. Ахмед Н. Ортогональные преобразования при обработке цифровых сигналов / Н. Ахмед, К. Р. Рао. – М.: Связь, 1980. – 248 с.

5. Чернов В. М. Быстрые алгоритмы дискретных косинусных преобразований коротких длин с минимальной вычислительной сложностью / В. М. Чернов, М. А. Чичёва // Известия Самарского научного центра РАН. – 1999. – Т. 2. – С. 241-248.

6. Сергеев В. В., Юзькив Р. Р. Параметрическая модель автокорреляционной функции космических гиперспектральных изображений. Компьютерная оптика, 2016, 40(3), с. 416-421.

7. Чочиа П. А. Двухмасштабная модель изображения / П. А. Чочиа // Кодирование и обработка изображений. – М.: Наука, 1988. – С. 69–87.

8. MacQueen J. Some methods for classification and analysis of multivariate observations / J. MacQueen // Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability. – 1967. – P. 281-297.

9. Arthur D. k-means++: the advantages of careful seeding / D. Arthur, S. Vassilvitskii // Proceedings of the 18th annual ACM-SIAM symposium on Discrete algorithms. – 2007. – P. 1027-1035.

10. ISO/IEC 10918-1. Information technology. Digital compression and coding of continuous-tone still images. Requirements and guidelines. – ISO/IEC JTC 1/SC 29 Coding of audio, picture, multimedia and hypermedia information, 1994. – 182 p.

11. NASA. AVIRIS Data Portal. URL: [https://aviris.jpl.nasa.gov/alt\\_locator/](https://aviris.jpl.nasa.gov/alt_locator/) (дата обращения: 29.04.2019).

12. Yuzkiv R. R. Transform-based coding method for remote sensing hyperspectral data compression / R. R. Yuzkiv, V. V. Sergeev // Procedia Engineering. – 2017. – Vol. 201. – P. 249-257.

А.А. Ямалтдинова, В.В. Мокшин

## ГЛУБОКОЕ ОБУЧЕНИЕ С ИСПОЛЬЗОВАНИЕМ БАЙЕСОВСКОЙ ОПТИМИЗАЦИИ В MATLAB

(Альметьевский филиал КНИТУ-КАИ им А.Н.Туполева)

Глубокое обучение в наше время стало направлением, которое стоит выше всего исследований в машинном обучении. Начавшись с архитектурных прорывов, которые давали возможность оперативно обучать глубокие нейросети, оно стало направляться и на другие стороны, отдавая набор результативных систем там, где для исполнения проблем необходим приближение какой-то сложной функции.