

Фрактальный подход к выбору коэффициента сжатия гиперспектральных изображений в методе 3D-SPIHT при условии последующей классификации восстанавливаемых изображений методом опорных векторов

Д.В. Учаев, Дм.В. Учаев, А.С. Есипов, Е.Г. Филатова

*Московский государственный университет геодезии и картографии
Москва, 105064, Россия
E-mail: d-uchaev@yandex.ru*

На протяжении последнего десятилетия наблюдается значительный рост интереса к решению прикладных задач с использованием гиперспектральных изображений, получаемых в процессе дистанционного зондирования Земли. Вместе с этим растет и потребность в высокоэффективных методах сжатия гиперспектральных изображений. Методы 3D-SPIHT являются одними из наиболее эффективных методов, используемых для сжатия гиперспектральных изображений. Одной из важнейших проблем при использовании методов 3D-SPIHT является выбор коэффициента сжатия в условиях, когда восстанавливаемые гиперспектральные изображения должны в дальнейшем быть подвергнуты процедуре классификации. В данной работе представлены результаты научных исследований влияния сжатия гиперспектральных изображений методом 3D-SPIHT на качество их классификации методом опорных векторов. На примере двух тестовых наборов данных Pavia University (ROSIS) и Salinas (AVIRIS) показано, что между качеством классификации и эталонными метриками оценки качества восстанавливаемых гиперспектральных изображений существует связь. Данная связь позволяет выделить три характерных диапазона коэффициента сжатия, при которых общая точность классификации практически не уменьшается, уменьшается незначительно и снижается катастрофически. На основе сделанных наблюдений предложен фрактальный подход к выбору коэффициента сжатия гиперспектральных изображений в методе 3D-SPIHT при условии последующей классификации восстанавливаемых изображений методом опорных векторов.

Ключевые слова: гиперспектральное изображение, 3D-SPIHT, машина опорных векторов, качество классификации, фрактал

*Одобрена к печати: 25.05.2017
DOI: 10.21046/2070-7401-2017-14-4-9-23*

Введение

Гиперспектральная съемка за последнее десятилетие прочно вошла в арсенал средств дистанционного зондирования во всем мире, доказав свою эффективность во многих областях деятельности человека (Bioucas-Dias et al., 2013). Однако важной проблемой, связанной с гиперспектральной съемкой, по-прежнему остается большой объем гиперспектральных изображений (ГИ), получаемых с ее помощью. Данная проблема приводит в конечном итоге не только к высокой стоимости хранилищ ГИ, но и к возрастанию времени обработки ГИ, а также к сложностям в управлении и передаче данных, в особенности со спутников на Землю (Учаев и др., 2016; Chang, 2013). Как результат, за последние два десятилетия было разработано множество методов сжатия, в той или иной мере решающих проблему уменьшения объема ГИ. Все методы сжатия ГИ могут быть разделены на две большие группы: методы сжатия без потерь и методы сжатия с потерями. В методах сжатия без потерь оригинальные ГИ кодируются без потери информации и могут быть полностью восстановлены в процессе декодирования. Реверсивность методов сжатия без потерь, без сомнения, полезное свойство, поскольку оригинальные ГИ всегда обладают большей информацией, чем любые варианты их обработки. Но поскольку кодирование без потерь

использует только статистическую избыточность ГИ, данные методы сжатия могут обеспечить коэффициенты сжатия $r = N_0 / N_f$ (где N_0 — количество бит в исходном файле; N_f — количество бит в восстановленном файле; $N_f = bpppb N_x \times N_y N_z$, здесь $bpppb$ (bits per pixel per band) — количество бит на пиксел на канал; N_x — ширина ГИ; N_y — высота ГИ; N_z — количество каналов ГИ), не превышающие трех (Serra-Sagristà, Aulí-Llinàs, 2008). В то же время методы сжатия ГИ с потерями допускают потерю информации и, как следствие, не предоставляют возможности полного восстановления сжатых ГИ. Однако теряемая при этом информация не всегда оказывается критически необходимой для дальнейшей обработки ГИ (Qian et al., 2001; Tang, Pearlman, 2006). Данное обстоятельство позволяет в процессе сжатия достигать больших значений r (20 и более), не теряя при этом существенно в качестве результата обработки ГИ. Учитывая это и то, что в 2015 г. уже был разработан стандарт сжатия ГИ без потерь (Consultative Committee for Space Data Systems, CCSDS 120.2-G-1 (Lossless..., 2015)), а аналогичного стандарта сжатия ГИ с потерями до сих пор не существует, большинство проводящихся на сегодняшний день исследований ориентировано на разработку и исследование методов сжатия ГИ с небольшой потерей информации.

Сжатие ГИ с потерями может выполняться либо независимо в каждом канале (двумерные методы), либо обработкой всего гиперкуба как единого массива данных (трехмерные методы). В целом, как было неоднократно показано, трехмерные методы оказываются более эффективными при сжатии ГИ, поскольку в них принимается в расчет корреляция, существующая между спектральными каналами ГИ (Kim, Xiong, Pearlman, 2000; Tang, Cho, Pearlman, 2003). При этом большинство таких методов основано на различных трехмерных преобразованиях исходных ГИ, например, дискретном вейвлет-преобразовании (Christophe, Mailhes, Duhamel, 2006; Lim, Sohn, Lee, 2001) или дискретном косинусном преобразовании (Abousleman, Marcellin, Hunt, 1995; Markman, Malah, 2001).

В данной работе объектом исследования является метод разбиения множества в иерархических деревьях (Set Partitioning In Hierarchical Trees (SPIHT)) (Pearlman, Said, 1998; Said, Pearlman, 1996). Ключевым отличием этого метода является то, что на любом этапе декодирования качество восстанавливаемого изображения будет наилучшим с точки зрения объема информации о данном изображении. Другая отличительная черта метода SPIHT состоит в использовании им вложенного кодирования. Это свойство можно определить следующим образом: если кодер, использующий вложенное кодирование, производит два изображения, объем (m) одного из которых меньше объема другого, то меньший файл совпадает с большим m битами (Сэлмон, 2004). Метод SPIHT был первоначально разработан для сжатия двумерных изображений естественных сцен (2D-SPIHT). Впоследствии были предложены различные обобщения данного метода, позволяющие сжимать и восстанавливать многослойные изображения (3D-SPIHT) (Dragotti, Poggi, Ragozini, 2000; Kim, Pearlman, 1997; Kim, Xiong, Pearlman, 2000; Tang, Cho, Pearlman, 2003). Сейчас методы 3D-SPIHT стали одними из наиболее популярных методов, используемых для сжатия ГИ. Их эффективность подтверждалась во множестве экспериментов. В частности, системы сжатия, основанные на модифицированном методе SPIHT, были успешно использованы

в программном обеспечении, установленном на космическом аппарате «Розетта» и автоматической межпланетной станции «Кассини» (Langevin, Forni, 2000).

Методы 3D-SPIHT, как и большинство методов сжатия, разрабатывались с целью минимизации среднеквадратической ошибки (СКО), рассчитываемой между оригинальным и восстановленным изображениями. Такой подход является вполне оправданным в условиях, когда область применения сжатых изображений не ограничена или неизвестна. Более того, подобный подход позволяет сравнивать разрабатываемые методы сжатия с общих позиций, выбирая тот, который позволяет достичь меньших значений СКО. Однако применительно к ГИ данный подход может привести к проблеме. Дело в том, что точность классификации не находится в прямой зависимости от СКО и может быть небольшой при малых значениях СКО. На эту проблему обращали внимание многие специалисты, изучавшие влияние методов сжатия на результаты классификации ГИ (см., например, (Penna et al., 2007)). Тем не менее, до сих пор исследований, посвященных данной проблеме, в целом крайне мало, а в отношении метода 3D-SPIHT всего лишь несколько (García-Vilchez et al., 2011; Lee et al., 2015; Liang et al., 2008). В связи с этим актуальным представляется рассмотрение задачи выбора параметров сжатия ГИ с учетом последующей классификации восстанавливаемых ГИ и, в частности, выбор коэффициента сжатия в методе 3D-SPIHT.

Цель данной работы — представить результаты исследований, направленных на разработку подхода к выбору коэффициента сжатия гиперспектральных изображений в методе 3D-SPIHT, предложенном в работе (Kim, Xiong, Pearlman, 2000), при условии последующей классификации восстанавливаемых изображений методом опорных векторов.

Классификатор, основанный на методе опорных векторов

Свои корни классификатор, основанный на методе опорных векторов (КМОВ) (Support Vector Classifier), имеет в статистической теории обучения, чья цель — создать математический инструментарий для восстановления зависимости между элементами пар «вход-выход» с целью предсказания будущего выхода по заданному входу, основываясь на гипотезе о существовании стохастического механизма, генерирующего такие пары (Вьюгин, 2014). Основная идея КМОВ состоит в возможности построения для заданного множества $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, где $\mathbf{x}_i \in \mathbb{R}^n$ — векторы признаков, а $y_i \in \{-1, +1\}$ ($1 \leq i \leq n$), линейного бинарного классификатора, основанного на поиске оптимального разделения классов в пространстве признаков с помощью так называемой «оптимальной разделяющей гиперплоскости» (ОРГ). При этом под ОРГ понимается гиперплоскость, удовлетворяющая неравенству $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1$ (где \mathbf{w} — перпендикуляр к ОРГ; b — константа), формально определяющему два условия: 1) все векторы данных, принадлежащие одному классу, должны быть расположены по одну сторону от ОРГ; 2) расстояние (зазор) между ближайшими векторами данных и ОРГ в обоих классах должно быть максимальным (Вапник, Червоненкис, 1974). Используя данную идею, в 1992 г. в работе (Boser, Guyon, Vapnik,

1992) было получено обобщение данного линейного классификатора на случай линейно неразделимых обучающих данных.

Пусть задана размеченная обучающая выборка $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, где $\mathbf{x}_i \in \mathbb{R}^n$ — векторы признаков, а $y_i \in \{-1, +1\}$ и нелинейное отображение в Гильбертово пространство $\Phi: \mathbb{R}^n \rightarrow \mathcal{H}$. Тогда КМОВ может быть определен как задача квадратичной оптимизации:

$$\begin{cases} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i(b) \rightarrow \min_{\mathbf{w}, \xi_i, b}, \\ y_i ((\Phi(\mathbf{x}_i) \cdot \mathbf{w}) + b) \geq 1 - \xi_i \text{ при } 1 \leq i \leq n, \\ \xi_i \geq 0 \text{ при } 1 \leq i \leq n, \end{cases} \quad (1)$$

где \mathbf{w} и b определяют описанный выше линейный классификатор в признаковом пространстве. Нелинейная функция Φ вводится в задачу с целью повышения вероятности линейной разделимости образов (Cover, 1965), а параметр регуляризации C позволяет регулировать отношение между максимизацией ширины разделяющей полосы и минимизацией суммы ошибок ξ_i .

По теореме Куна-Таккера система (1) может быть сведена к задаче поиска седловой точки функции Лагранжа:

$$\begin{cases} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)) \rightarrow \max_{\alpha}, \\ 0 \leq \alpha_i \leq C, \\ \sum_{i=1}^n \alpha_i y_i = 0, \end{cases} \quad (2)$$

где $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)$ — вектор множителей Лагранжа.

Заметим, что все отображения Φ , используемые в системе (2), встречаются в форме скалярных произведений. Это позволяет определить нелинейную функцию ядра:

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)). \quad (3)$$

Тогда, пользуясь определением (3), получим решение двойственной задачи (2) $\alpha^0 = (\alpha_1^0, \alpha_2^0, \dots, \alpha_n^0)$. Учитывая все вышесказанное, решающая функция, реализуемая КМОВ для любого вектора \mathbf{x} из тестируемой выборки, определяется посредством следующей знаковой функции:

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^n y_i \alpha_i^0 K(\mathbf{x}_i, \mathbf{x}) + b^0 \right), \quad (4)$$

где b^0 — константа, которая может быть легко вычислена из α^0 (Varnik, 1995). Следует также обратить внимание, что на практике суммирование в формуле (4) идет не по всей

обучающей выборке, а только по тем векторам, для которых $\alpha_i^0 \neq 0$ (свойство разреженности). Таким образом, данный подход к классификации принимает в расчет только ближайшие к границе класса векторы данных, которые принято называть опорными векторами.

Методика обработки тестовых наборов данных

Качество классификации с помощью КМОВ, как и качество классификации другими классификаторами, может быть количественно оценено посредством матрицы ошибок и ряда производных количественных показателей: общей точности (Overall Accuracy (OA)), точности производителя (Producer's Accuracy (PA)), точности пользователя (User's Accuracy (UA)), коэффициента каппа (κ) и др. (Congalton, Green, 2008). Однако на все эти оценки помимо качества классифицируемого ГИ в той или иной мере влияют и другие факторы, наиболее значимыми из которых являются следующие:

- алгоритм выбора обучающего и тестового наборов данных,
- вид функции ядра K ,
- алгоритм поиска оптимальных значений параметров функции ядра и регуляризации C .

Учитывая это обстоятельство, а также большие временные затраты на проведение классификации КМОВ, в данной работе мы применяли методику обработки тестовых наборов данных, включающую в себя следующие шаги:

1. Подготовка тестовых ГИ.
 - 1.1. Удаление малоинформативных каналов тестовых ГИ.
 - 1.2. Пространственная обрезка тестовых ГИ с целью устранения областей, для которых отсутствует эталонная информация (ground truth data).
 - 1.3. Сокращение или увеличение (т.е. добавление пикселей, содержащих значение NoData) спектральной и пространственной размерностей ГИ с целью упрощения работы программного обеспечения, реализующего метод 3D-SPIHT.
2. Сжатие и восстановление тестовых ГИ, полученных на первом шаге.
 - 2.1. Сжатие тестовых ГИ со значением $bpppb_{\max} = N_0 / (N_x N_y N_z)$.
 - 2.2. Восстановление тестовых ГИ из сжатого битового потока со значениями параметра $bpppb = 0,1; 0,2; \dots; 3,0; 5,0; \dots; bpppb_{\max}$ (данная последовательность была выбрана эмпирически).
3. Оценка качества восстановленных на шаге 2 ГИ.
 - 3.1. Выбор информативных эталонных метрик оценки качества ГИ.
 - 3.2. Расчет для восстановленных на шаге 2 ГИ значений выбранных эталонных метрик оценки качества.
4. Извлечение производных векторов признаков из ГИ (исходных векторов признаков), полученных на шаге 1 и 2, с использованием метода главных компонент (в данном исследовании использовались первые 15 компонент).

5. Создание тестовой выборки с использованием 90% эталонных данных и стратегии слепого случайного отбора (в работе (Liu et al., 2013) было показано, что данная стратегия превосходит по скорости и не уступает по качеству интеллектуальным стратегиям отбора).

6. Создание обучающей выборки с использованием 1% разности исходного набора эталонных данных и тестовой выборки, созданной на шаге 5. Использование всего лишь одного процента разности исходного набора эталонных данных и тестовой выборки обусловлено потребностью исследований, выполняемых авторами работы в настоящее время, результаты которых будут изложены в последующих работах.

7. Получение статистически достоверных оценок математического ожидания и стандартного отклонения показателя ОА для векторов признаков, полученных на шаге 4 (шаги 7.1 и 7.2 повторяются в цикле 10 раз; данное число было выбрано, исходя из компромисса между требованием получить статистически значимые оценки классификации и длительностью процедуры обработки векторов признаков на данном шаге).

7.1. Обучение КМОВ с использованием радиальной базисной функции (Radial Basis Function (RBF)) и метода пятикратной перекрестной проверки (cross-validation) (во множестве работ (см., например, (Melgani, Bruzzone, 2004; Shah et al., 2003)) было показано, что качество классификации с использованием RBF в большинстве случаев выше, чем с использованием других наиболее популярных функций ядра: линейной, полиномиальной функций или сигмоиды).

7.2. Оценка значения показателя ОА по результатам классификации тестовой выборки обученным на шаге 7.1 КМОВ.

7.3. Расчет оценок математического ожидания и стандартного отклонения показателя ОА по значениям показателя ОА, полученным на шаге 7.2.

8. Расчет 95%-х доверительных интервалов для оценок математического ожидания показателей ОА, рассчитанных на шаге 7.

9. Практическая реализация описанной выше методики потребовала использования специализированного программного обеспечения. В данной работе применялись следующие бесплатные программные средства:

- программа QccPack, содержащая реализацию метода 3D-SPIHT — модуль QccPackSPIHT-0.61-1 (<http://qccpack.sourceforge.net>) (Kim, Xiong, Pearlman, 2000);
- программа EnMAP-Box 2.2.1, реализующая базовый инструментарий для работы с ГИ (просмотр, пространственная обрезка и удаление спектральных каналов; построение обучающей и тестовой выборок; классификация, основанная на методе опорных векторов) (<http://www.enmap.org/?q=enmapbox>) (van der Linden et al., 2015);
- программа ImAnalysis, реализующая расчет эталонных метрик оценки качества ГИ (<http://www.pansharp.com/applications/imanalysis>, <https://www.mathworks.com/matlabcentral/fileexchange/41464-image-quality-index-analysis-gui>) (Vaiopoulos, 2011).

Описание тестовых наборов данных

В данной работе приведены результаты исследований двух тестовых наборов данных, размещенных в сети Интернет в свободном доступе по адресу http://www.ehu.es/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes: Pavia University и Salinas (рис. 1, 2).

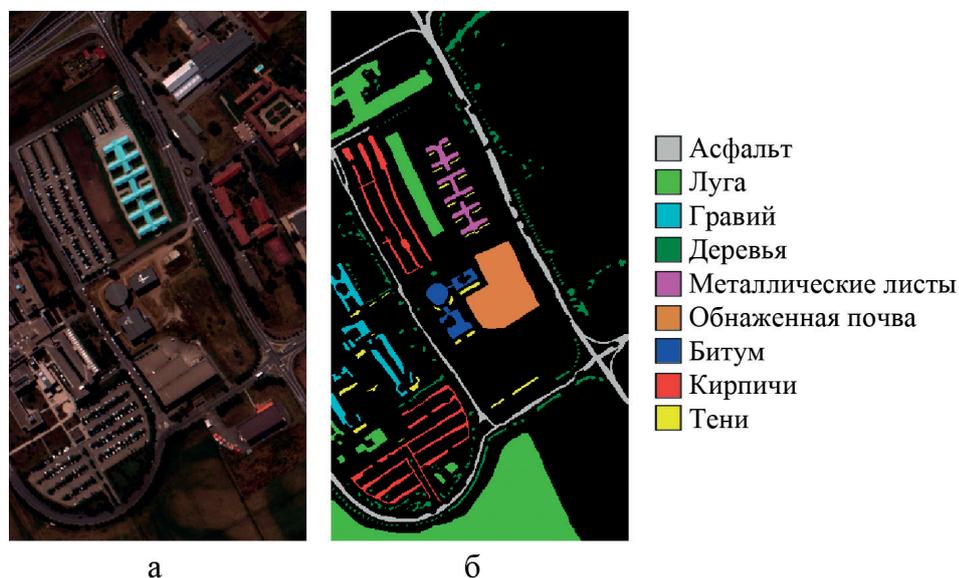


Рис. 1. Тестовый набор данных Pavia University: а — цветной RGB-композит, составленный из 46 (R), 27 (G) и 10 (B) каналов ГИ; б — эталонное разбиение на классы

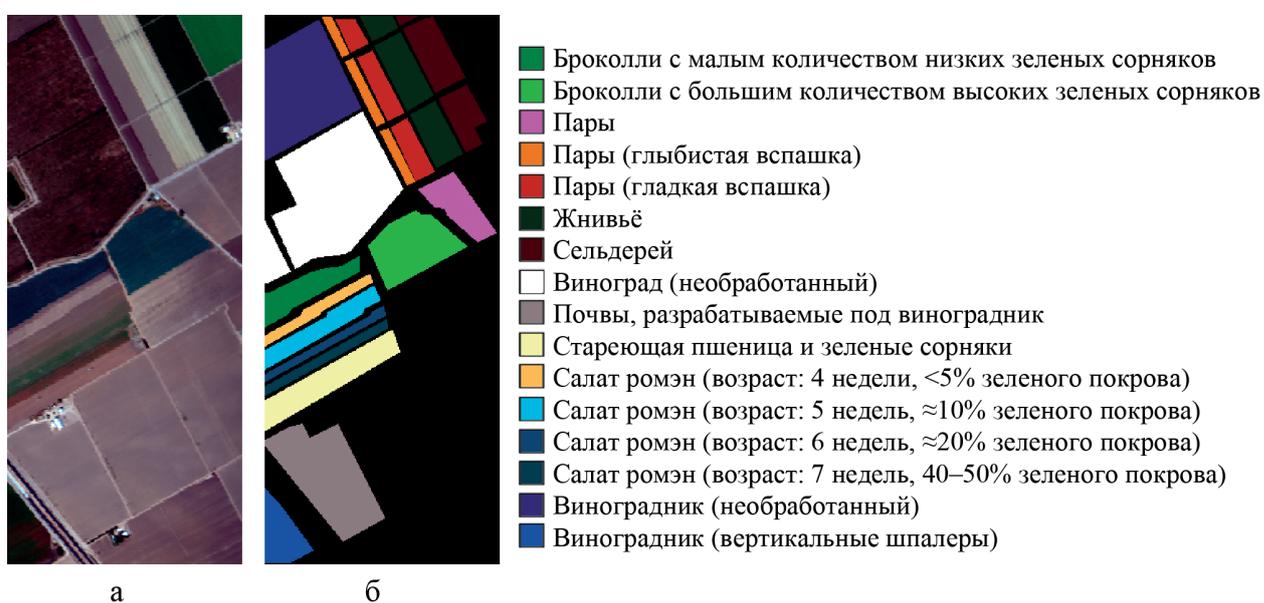


Рис. 2. Тестовый набор данных Salinas: а — цветной RGB-композит, составленный из 35 (R), 19 (G) и 9 (B) каналов ГИ; б — эталонное разбиение на классы

Набор данных Pavia University содержит ГИ территории Павийского университета (Италия), полученное с помощью авиационного гиперспектрометра ROSIS 8 июля 2002 г., и соответствующее ему подтвержденное наземными исследованиями эталонное разбиение

на классы (Gamba, 2004). ГИ имеет размеры 340×610 пикселей и 103 спектральных канала. Его среднее пространственное разрешение составляет 1,3 м. На изображении представлены девять классов, характерные для городского ландшафта.

Набор данных Salinas включает в себя ГИ территории южнее города Гринфилд в долине Салинас (Калифорния, США), полученное с помощью авиационного гиперспектрометра AVIRIS 9 октября 1998 г., и соответствующее ему подтвержденное наземными исследованиями эталонное разбиение на классы. ГИ имеет размеры 217×512 пикселей и 204 спектральных канала. Его среднее пространственное разрешение составляет 3,7 м. На изображении представлены 16 классов, характерных для сельскохозяйственного ландшафта (Gualtieri et al., 1999).

Для целей исследования каждое из тестовых ГИ было сперва подвергнуто предварительной обработке в соответствии с методикой, описанной выше. В результате этой обработки были сформированы производные ГИ размером $320 \times 576 \times 103$ (Pavia University) и $192 \times 512 \times 192$ (Salinas), которые и стали исходными ГИ для дальнейшего исследования.

Результаты исследований

В работе исследовались семь метрик оценки качества ГИ: относительная средняя спектральная ошибка (RASE), относительная систематическая ошибка (Bias), коэффициент корреляции (CC), относительная разность дисперсий (DIV), безразмерная глобальная относительная ошибка синтеза (ERGAS), универсальный индекс качества изображения (Q), квадратный корень из среднеквадратической ошибки (RMSE) (Vaiopoulos, 2011). Зависимости значений данных метрик (M) от r , рассчитанные для каждого тестового ГИ, приведены на *рис. 3, 4*. Как видно из рисунков, значения метрик CC и Q являются близкими, что обусловлено природой данных метрик: метрика Q учитывает, помимо прочего, корреляционную связь, существующую между исходным и восстановленным изображениями. При этом обе метрики, в отличие от остальных, демонстрируют слабую зависимость от r для обоих тестовых ГИ. С другой стороны, метрики RASE, Bias, DIV, ERGAS и RMSE оказываются более «чувствительными» к потере качества, происходящей при сжатии ГИ методом 3D-SPIHT, и имеют близкое поведение, существенно отличаясь лишь порядком величин. Анализ данных зависимостей позволяет выделить на них три характерных участка: начальный, ускоренный и замедленный.

Начальный участок начинается при $r=1$ и заканчивается при $r \approx 10$. На данном диапазоне значений r качество восстановленного ГИ мало отличается от качества исходного ГИ, а значения ОА в среднем остаются достаточно высокими, держась в районе 83,0 и 89,5 для наборов данных Pavia University и Salinas соответственно (*рис. 5*). При дальнейшем увеличении коэффициента сжатия качество восстановленного ГИ начинает резко падать, что выражается в существенно более высокой скорости роста значений метрик оценки качества RASE, Bias, DIV, ERGAS и RMSE. В настоящем исследовании было установлено,

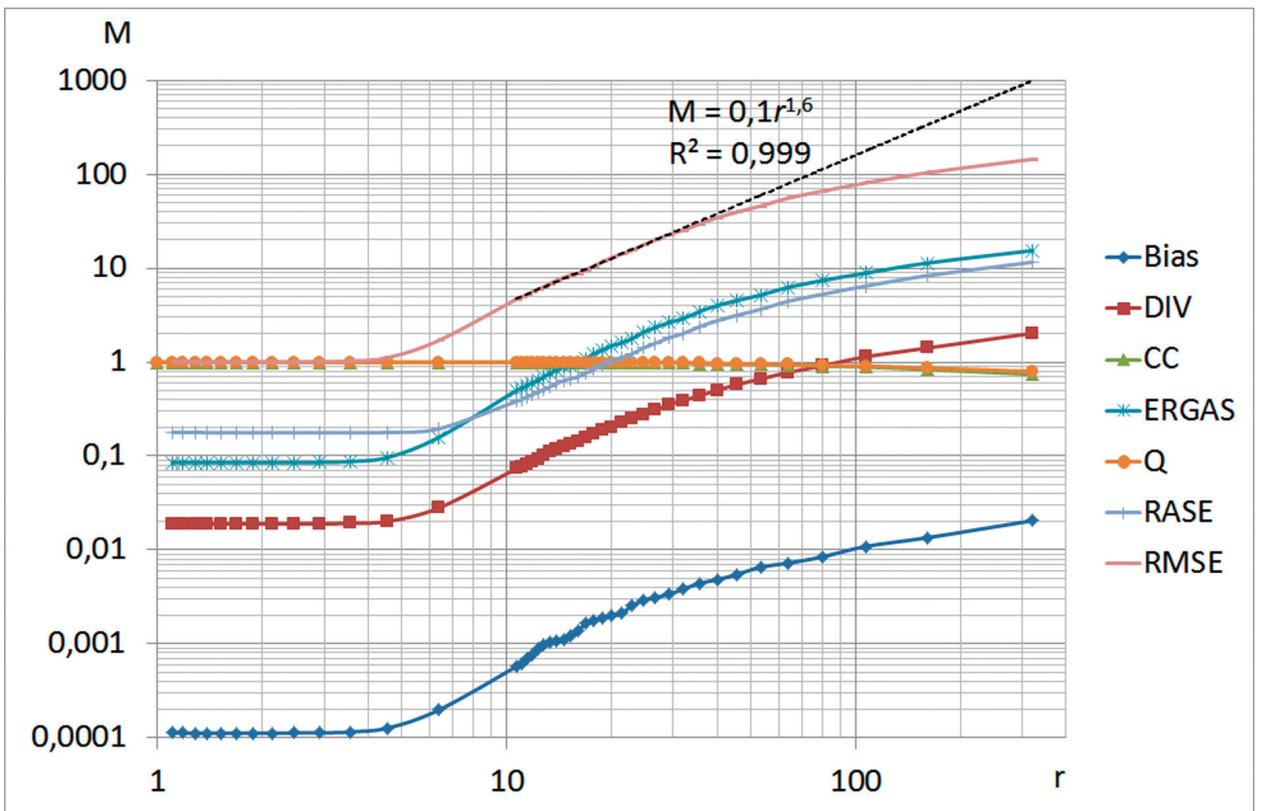


Рис. 3. Зависимости $M(r)$, построенные для восстановленного ГИ Pavia University. Пунктирной линией показана степенная функция, аппроксимирующая участок быстрого роста значений метрики RMSE

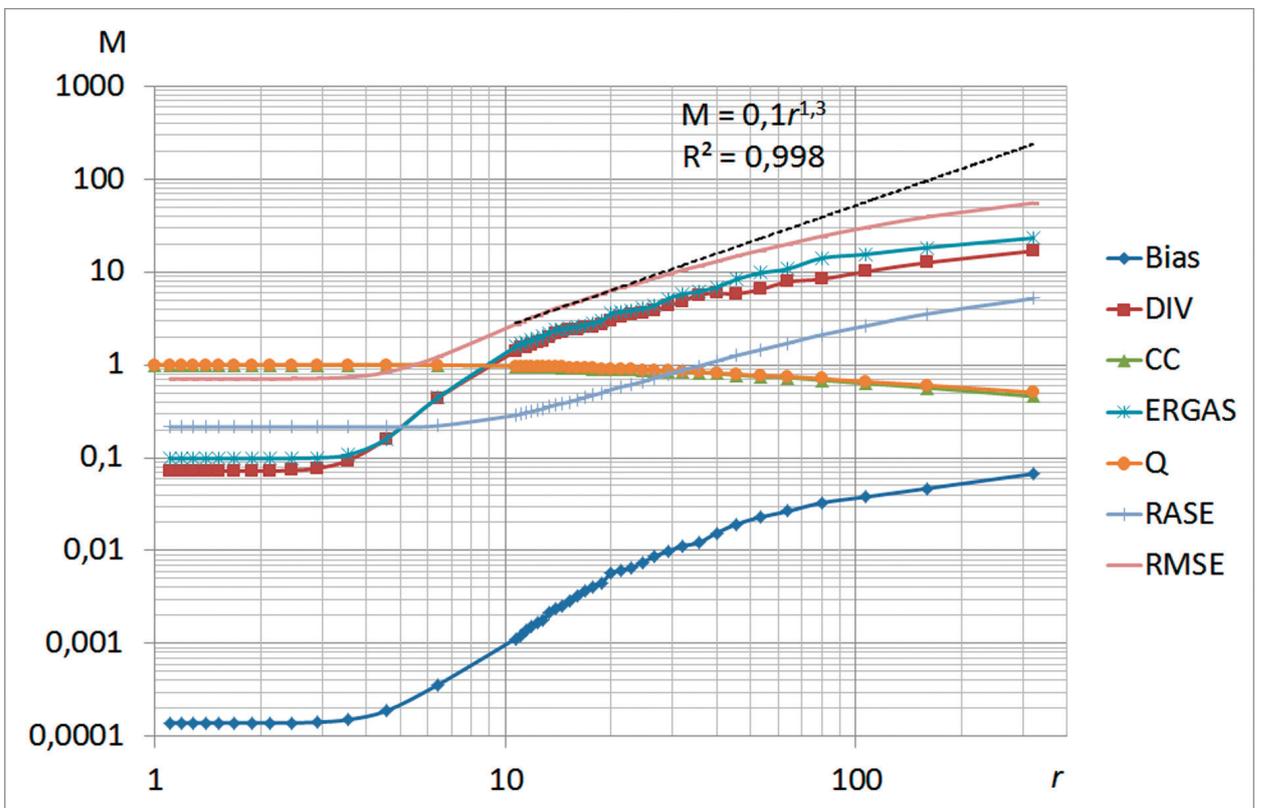


Рис. 4. Зависимости $M(r)$, построенные для восстановленного ГИ Salinas. Пунктирной линией показана степенная функция, аппроксимирующая участок быстрого роста значений метрики RMSE

что на участке ускоренного роста данные метрики демонстрируют фрактальное (самоподобное) поведение. Более того, при сопоставлении графиков $OA(r)$ и $M(r)$ было обнаружено, что значение верхней границы самоподобия (r_1) метрики RMSE наиболее близко к значению верхней границы диапазона r , на котором значения OA в среднем не уменьшаются или уменьшаются незначительно. Так, для тестовых наборов данных Pavia University и Salinas значения r_1 равны 29 ± 3 и 21 ± 3 соответственно. При этом, как видно на *рис. 5*, к концу диапазона $10 < r < r_1$ значение OA для набора данных Pavia University уменьшается незначительно (с $82,6 \pm 0,7$ до $81,9 \pm 0,6$), а для набора данных Salinas и вовсе практически не изменяется ($89,2 \pm 0,2$). Если же посмотреть на динамику изменения значений OA внутри рассматриваемого интервала r , то, как и при $r \leq 10$, для обоих тестовых наборов данных обнаруживаются значения r , при которых точность классификации немного уменьшается. Наблюдаемое уменьшение значений OA связано с множеством факторов, среди которых наиболее важными являются малый размер обучающей выборки и наличие в обучающей выборке векторов признаков с низким дешифровочным потенциалом (Lee et al., 2010).

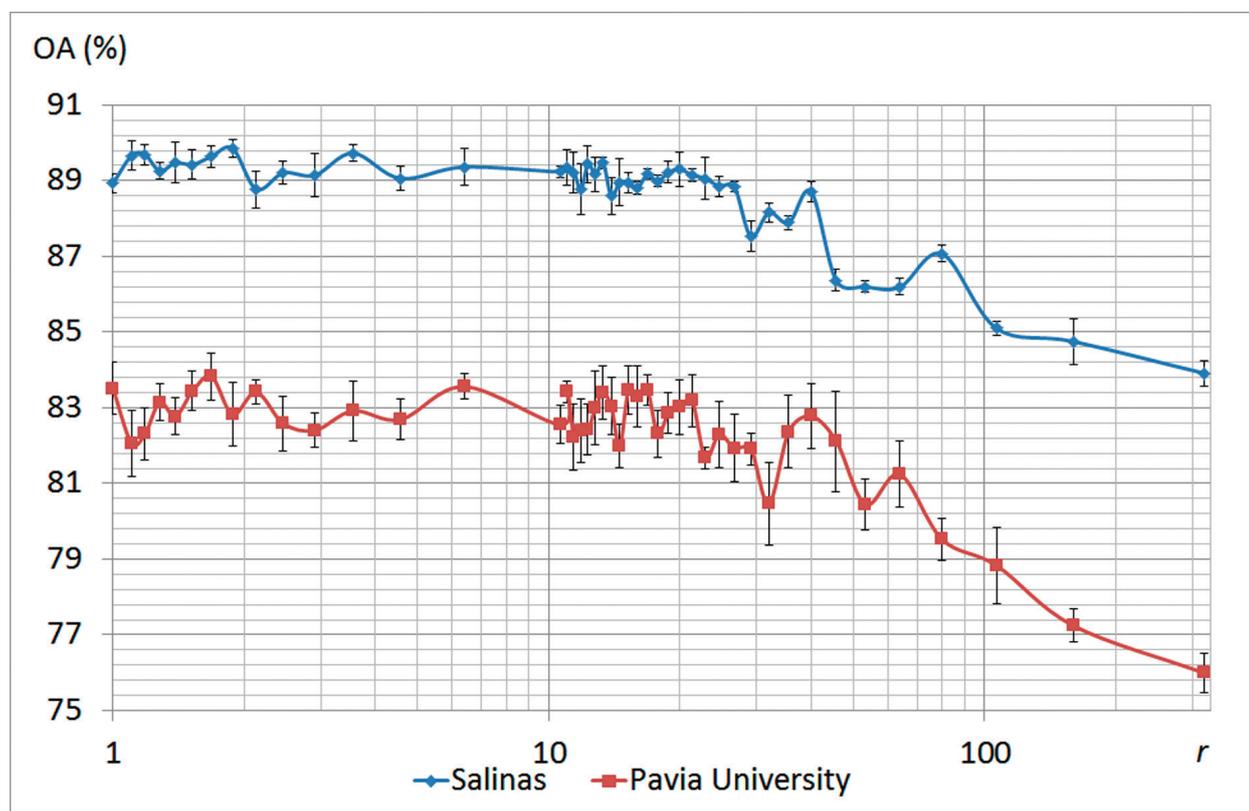


Рис. 5. Зависимости $OA(r)$, построенные по результатам оценки качества классификации с помощью КМОВ тестовых ГИ, восстановленных после сжатия методом 3D-SPIHT

Однако следует также заметить, что при некоторых значениях r качество классификации может не измениться и даже вырасти относительно качества классификации исходного ГИ. Эта ситуация была описана в работах (García-Vilchez et al., 2011; Lee et al., 2015) и связана, главным образом, со сглаживающим эффектом, возникающим при сжатии и восстановлении ГИ, и ограниченным размером тестовой выборки.

Участок ускоренного роста исследуемых кривых плавно переходит в участок замедленного роста, соответствующий $r \geq r_1$. На данном участке скорость уменьшения значений метрик RASE, Bias, DIV, ERGAS и RMSE, рассчитанных для восстановленного ГИ, существенно снижается. Наличие данного участка позволяет сделать вывод, что начиная с некоторого значения r зависимость значений метрик RASE, Bias, DIV, ERGAS и RMSE от r начинает уменьшаться. С другой стороны, скорость роста функций $CC(r)$, $Q(r)$ и $OA(r)$, наоборот, растет. Таким образом, метрики RASE, Bias, DIV, ERGAS и RMSE, в отличие от метрик CC и Q , не отражают возрастающую при $r \geq r_1$ потерю дешифровочных свойств классифицируемых векторов признаков.

На основе полученных результатов был сформулирован фрактальный подход к выбору коэффициента сжатия (r) ГИ, имеющего $N_x \times N_y \times N_z$ пикселей и N_0 бит информации, с помощью метода 3D-SPIHT при условии последующей классификации восстанавливаемого ГИ с помощью КМОВ. Суть данного подхода состоит в использовании для сжатия исходного ГИ $r \leq r_1$, где r_1 — верхняя граница диапазона самоподобия, оценка которой может быть получена следующим способом, учитывающим тот факт, что в большинстве реализаций алгоритма 3D-SPIHT входным параметром является значение $bpppb$, а не r :

1. Сжатие ГИ со значением $bpppb_{\max} = N_0 / (r_{\min} N_x \times N_y \times N_z)$, где $r_{\min} = 10$.
2. Восстановление набора ГИ из сжатого битового потока со значениями параметра $bpppb = 0,1; 0,2; \dots; bpppb_{\max}$.
3. Расчет для восстановленных на шаге 2 ГИ множества значений $RMSE(bpppb)$.
4. Расчет множества значений $r(bpppb) = N_0 / (bpppb N_x N_y N_z)$.
5. Построение зависимости $RMSE(r)$.
6. Отыскание интервалов (r_{\min}, r) , для которых подтверждается гипотеза, что зависимость $RMSE(r)$ аппроксимируется степенной функцией.
7. Если на шаге 6 найден хотя бы один интервал (r_{\min}, r) , то присваивание r_1 значения верхней границы диапазона самоподобия, при котором $RMSE(r)$ наилучшим образом аппроксимируется степенной функцией. В противном случае, $r_1 = 10$.

При этом следует заметить, что при восстановлении сжатых ГИ целесообразно производить поиск значения r , при котором качество классификации наиболее высокое.

Заключение

В результате проведенных исследований были получены следующие научные и практические результаты.

1. Впервые обнаружено, что зависимости $RASE(r)$, $Bias(r)$, $DIV(r)$, $ERGAS(r)$ и $RMSE(r)$ на участке ускоренного роста демонстрируют фрактальное поведение и могут быть с высокой степенью точности аппроксимированы степенными функциями с дробными показателями.

2. Получено практическое подтверждение выводам, сделанным в работах (García-Vilchez et al., 2011; Lee et al., 2015), что с ростом коэффициента сжатия точность классификации ГИ, восстановленных с потерями, может увеличиваться, а в некоторых случаях и превышать точность классификации оригинального ГИ.

3. На основе сделанных наблюдений предложен фрактальный подход к выбору коэффициента сжатия ГИ методом 3D-SPIHT при условии последующей классификации восстанавливаемых ГИ с помощью КМОВ.

В дальнейшем авторы настоящей работы планируют проверить эффективность предлагаемого фрактального подхода к выбору коэффициента сжатия в отношении ГИ, получаемых с других гиперспектральных съемочных систем (например, Huperion и «Ресурс-П» № 1). Кроме того, планируется исследовать возможность применения предлагаемого в данной работе подхода в отношении других методов сжатия и классификации. Проводимые работы в перспективе могут позволить сократить затраты на хранение и передачу ГИ в ситуациях, когда конечной целью обработки ГИ является построение классификационных карт.

Работа выполнена по инициативному научному проекту 5.6470.2017/БЧ в рамках базовой части государственного задания Минобрнауки РФ при поддержке гранта Президента Российской Федерации по договору № 14.Z56.16.8526-МК от 14.03.2016 (МК-8526.2016.5).

Литература

1. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов. Статистические проблемы обучения. М.: Наука, 1974. 416 с.
2. Вьюгин В.В. Математические основы машинного обучения и прогнозирования. М.: МЦНМО, 2014. 304 с.
3. Сэломон Д. Сжатие данных, изображений и звука: пер. с англ. М.: Техносфера, 2004. 368 с.
4. Учаев Д.В., Бобков А.Е., Малинников В.А., Учаев Дм.В. Управление гиперспектральными изображениями в процессе научно-исследовательской деятельности малых коллективов // Современные проблемы дистанционного зондирования Земли из космоса. 2016. Т. 13. № 6. С. 233–248.
5. Aboussleman G.P., Marcellin M.W., Hunt B.R. Compression of hyperspectral imagery using the 3-D DCT and hybrid DPCM/DCT // IEEE Trans. Geosci. Remote Sens. 1995. Vol. 33. No. 1. P. 26–34.
6. Bioucas-Dias J.M., Plaza A., Camps-Valls G., Scheunders P., Nasrabadi N., Chanussot J. Hyperspectral Remote Sensing Data Analysis and Future Challenges // IEEE Geosci. Remote Sens. Mag. 2013. Vol. 1. No. 2. P. 6–36.
7. Boser B.E., Guyon I.M., Vapnik V.N. A Training Algorithm for Optimal Margin Classifiers // Proc. 5th Annual Workshop on Computational Learning Theory (COLT'92). New York. 1992. P. 144–152.
8. Chang C.-I. Hyperspectral data processing. Algorithm design and analysis. N.Y.: Wiley, 2013. 1151 p.
9. Christophe E., Mailhes C., Duhamel P. Best Anisotropic 3-D Wavelet Decomposition in a Rate-Distortion Sense // Proc. IEEE Intern. Conf. Acoustics Speech and Signal Processing, 2006 (ICASSP 2006). Toulouse. 2006. P. II-17–II-20.
10. Congalton R.G., Green K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. 2nd ed. Boca Raton: CRC Press, 2008. 210 p.
11. Cover T.M. Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition // IEEE Trans. Electron. Comput. 1965. Vol. EC-14. No. 3. P. 326–334.
12. Dragotti P.L., Poggi G., Ragozini A.R.P. Compression of multispectral images by three-dimensional SPIHT algorithm // IEEE Trans. Geosci. Remote Sens. 2000. Vol. 38. No. 1. P. 416–428.
13. Gamba P. A collection of data for urban area characterization // Proc. IEEE International Geoscience and Remote Sensing Symp., 2004 (IGARSS 2004). Anchorage. 2004. P. 69–72.
14. García-Vilchez F., Muñoz-Mari J., Zorzea M., Blanes I., González-Ruiz V., Camps-Valls G., Plaza A., Serra-Sagristà J. On the Impact of Lossy Compression on Hyperspectral Image Classification and Unmixing // IEEE Geosci. Remote Sens. Lett. 2011. Vol. 8. No. 2. P. 253–257.
15. Gualtieri J.A., Chettri S.R., Cromp R.F., Johnson L.F. Support Vector Machine Classifiers as Applied to AVIRIS Data // Summaries of the Eighth JPL Airborne Earth Science Workshop. Nevada. 1999. P. 217–227.

16. Kim B.-J., Pearlman W.A. An embedded wavelet video coder using three-dimensional set partitioning in hierarchical trees (SPIHT) // Proc. Data Compression Conf., 1997 (DCC'97). Snowbird. 1997. P. 251–260.
17. Kim B.-J., Xiong Z., Pearlman W.A. Low bit-rate scalable video coding with 3-D set partitioning in hierarchical trees (3-D SPIHT) // IEEE Trans. Circuits Syst. Video Technol. 2000. Vol. 10. No. 8. P. 1374–1387.
18. Langevin Y., Forni O. Image and spectral image compression for four experiments on the ROSETTA and Mars Express missions of ESA // Proc. SPIE. Applications of Digital Image Processing XXIII. 2000. Vol. 4115. P. 364–373.
19. Lee C., Choi E., Jeong T., Lee S., Lee J. Compression of hyperspectral images with discriminant features enhanced // J. Appl. Remote Sens. 2010. Vol. 4. No. 1. P. 041764.
20. Lee C., Youn S., Baek J.Y., Sagristà J.S. Effects of compression on classification performance and discriminant information preservation in remotely sensed data // Proc. SPIE. Satellite Data Compression, Communications, and Processing XI. 2015. Vol. 9501. P. 950103.
21. Liang Z., Xinming T., Guo Z., Xiaoliang W. Effects of JPEG2000 and SPIHT Compression on Image Classification // Proc. 21st ISPRS Congress Technical Commission VII. 2008. P. 541–544.
22. Lim S., Sohn K., Lee C. Compression for hyperspectral images using three dimensional wavelet transform // Proc. IEEE Intern. Geoscience and Remote Sensing Symp., 2001 (IGARSS 2001). Scanning the Present and Resolving the Future. Sydney. 2001. P. 109–111.
23. Liu X., Beltran J.F., Mohanchandra N., Toussaint G.T. On Speeding Up Support Vector Machines: Proximity Graphs Versus Random Sampling for Pre-Selection Condensation // Intern. J. Computer, Electrical, Automation, Control and Information Engineering. 2013. Vol. 7. No. 1. P. 133–140.
24. Lossless Multispectral and Hyperspectral Image Compression standard. Green Book. Informational Report, Issue 1. CCSDS 120.2-G-1. Washington: The Consultative Committee for Space Data Systems, 2015. 99 p.
25. Markman D., Malah D. Hyperspectral image coding using 3D transforms // Proc. Intern. Conf. Image Processing, 2001 (ICIP 2001). Thessaloniki. 2001. Vol. 1. P. 114–117.
26. Melgani F., Bruzzone L. Classification of Hyperspectral Remote Sensing Images With Support Vector Machines // IEEE Trans. Geosci. Remote Sens. 2004. Vol. 42. No. 8. P. 1778–1790.
27. Pearlman W.A., Said A. Data compression using set partitioning in hierarchical trees: Patent. 5764807 United States. 1998.
28. Penna B., Tillo T., Magli E., Olmo G. Transform Coding Techniques for Lossy Hyperspectral Data Compression // IEEE Trans. Geosci. Remote Sens. 2007. Vol. 45. No. 5. P. 1408–1421.
29. Qian S.-E., Hollinger A.B., Dutkiewicz M., Tsang H., Zwick H., Freemantle J.R. Effect of lossy vector quantization hyperspectral data compression on retrieval of red-edge indices // IEEE Trans. Geosci. Remote Sens. 2001. Vol. 39. No. 7. P. 1459–1470.
30. Said A., Pearlman W.A. A new, fast, and efficient image codec based on set partitioning in hierarchical trees // IEEE Trans. Circuits Syst. Video Technol. 1996. Vol. 6. No. 3. P. 243–250.
31. Serra-Sagristà J., Auli-Llinàs F. Remote Sensing Data Compression // Computational Intelligence for Remote Sensing Studies in Computational Intelligence / eds. M. Graña, R.J. Duro. Berlin, Heidelberg: Springer, 2008. P. 27–61.
32. Shah C.A., Watanachaturaporn P., Varshney P.K., Arora M.K. Some recent results on hyperspectral image classification // Proc. IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data, 2003 (WARSD 2003). Greenbelt. 2003. P. 346–353.
33. Tang X., Cho S., Pearlman W.A. 3D set partitioning coding methods in hyperspectral image compression // Proc. Intern. Conf. Image Processing, 2003 (ICIP 2003). Barcelona. 2003. Vol. 2. P. II-239–II-242.
34. Tang X., Pearlman W.A. Lossy-To-Lossless Block-Based Compression of Hyperspectral Volumetric Data // Proc. Intern. Conf. Image Processing, 2006 (ICIP 2006). Atlanta. 2006. P. 1133–1136.
35. Vaiopoulos A.D. Developing Matlab scripts for image analysis and quality assessment // Proc. SPIE. Earth Resources and Environmental Remote Sensing. GIS Applications II. 2011. Vol. 8181. P. 81810B.
36. van der Linden S., Rabe A., Held M., Jakimow B., Leitão P.J., Okujeni A., Schwieder M., Suess S., Hostert P. The EnMAP-Box — A Toolbox and Application Programming Interface for EnMAP Data Processing // Remote Sens. 2015. Vol. 7. No. 9. P. 11249–11266.
37. Vapnik V.N. The Nature of Statistical Learning Theory. N.Y.: Springer Science and Business Media, 1995. 201 p.

Fractal approach to the choice of the compression ratio of hyperspectral images in the 3D–SPIHT method under the condition of subsequent classification of the decompressed images by the support vector machine

D.V. Uchaev, Dm.V. Uchaev, A.S. Esipov, E.G. Filatova

Moscow State University of Geodesy and Cartography, Moscow 105064, Russia
E-mail: d-uchaev@yandex.ru

During the past decade, there has been a considerable growth of interest in the solution of applied problems using hyperspectral remote sensing images. Along with this growth, the need for highly effective methods of hyperspectral image compression also increases. 3D-SPIHT methods are one of the most effective methods used to compress hyperspectral images. One of the most important problems in the use of 3D-SPIHT methods is the choice of the compression ratio in conditions when decompressed hyperspectral images should be further subjected to classification. In this paper, results of a research on the impact of 3D-SPIHT compression of hyperspectral images on the quality of their classification by the support vector machine are presented. Using two test data sets, “Pavia University” (ROSIS) and “Salinas” (AVIRIS), it is shown that there is a relationship between the quality of classification and full-reference quality metrics of decompressed hyperspectral images. This relationship allows distinguishing three typical ranges of the compression ratio, at which the overall accuracy of the classification does not practically decrease, decreases slightly and decreases greatly. Based on the observations, a fractal approach to the choice of the compression ratio of hyperspectral images in the 3D-SPIHT method under the condition of subsequent classification of the decompressed images by the support vector machine is proposed.

Keywords: hyperspectral image, 3D-SPIHT, support vector machine, classification quality, fractal

Accepted: 25.05.2017

DOI: 10.21046/2070-7401-2017-14-4-9-23

References

1. Vapnik V.N., Chervonenkis A.Ya., *Teoriya raspoznavaniya obrazov. Statisticheskie problemy obucheniya* (Theory of pattern recognition. Statistical problems of training), Moscow: Nauka, 1974, 416 p.
2. V'yugin V.V., *Matematicheskie osnovy mashinnogo obucheniya i prognozirovaniya* (Mathematical Foundations of Machine Learning and Forecasting), Moscow: MTsNMO, 2014, 304 p.
3. Selomon D., *Szhatie dannykh, izobrazhenii i zvuka* (A Guide to Data Compression Methods), Moscow: Tekhnosfera, 2004, 368 p.
4. Uchaev D.V., Bobkov A.E., Malinnikov V.A., Uchaev Dm.V., Upravlenie giperspektral'nymi izobrazheniyami v protsesse nauchno-issledovatel'skoi deyatel'nosti malykh kollektivov (Management of hyperspectral images for scientific research of small teams), *Sovremennyye problemy distantsionnogo zondirovaniya Zemli iz kosmosa*, 2016, Vol. 13, No. 6, pp. 233–248.
5. Abousleman G.P., Marcellin M.W., Hunt B.R. Compression of hyperspectral imagery using the 3-D DCT and hybrid DPCM/DCT, *IEEE Trans. Geosci. Remote Sens.*, 1995, Vol. 33, No. 1, pp. 26–34.
6. Bioucas-Dias J.M., Plaza A., Camps-Valls G., Scheunders P., Nasrabadi N., Chanussot J., Hyperspectral Remote Sensing Data Analysis and Future Challenges, *IEEE Geosci. Remote Sens. Mag.*, 2013, Vol. 1, No. 2, pp. 6–36.
7. Boser B.E., Guyon I.M., Vapnik V.N., A Training Algorithm for Optimal Margin Classifiers, *Proceedings of the Fifth Annual Workshop on Computational Learning Theory (COLT'92)*, New York, 1992, pp. 144–152.
8. Chang C.-I., *Hyperspectral data processing. Algorithm design and analysis*, New York: Wiley, 2013, 1151 p.
9. Christophe E., Mailhes C., Duhamel P., Best Anisotropic 3-D Wavelet Decomposition in a Rate-Distortion Sense, *Proc. of the IEEE International Conference on Acoustics Speech and Signal Processing, 2006 (ICASSP 2006)*, Toulouse, 2006, pp. II-17-II-20.
10. Congalton R.G., Green K., *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, Boca Raton: CRC Press, 2008, 210 p.
11. Cover T.M., Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition, *IEEE Trans. Electron. Comput.*, 1965, Vol. EC-14, No. 3, pp. 326–334.
12. Dragotti P.L., Poggi G., Ragozini A.R.P., Compression of multispectral images by three-dimensional SPIHT algorithm, *IEEE Trans. Geosci. Remote Sens.*, 2000, Vol. 38, No. 1, pp. 416–428.
13. Gamba P., A collection of data for urban area characterization, *Proc. of the IEEE International Geoscience and Remote Sensing Symposium, 2004 (IGARSS 2004)*, Anchorage, 2004, pp. 69–72.
14. García-Vilchez F., Muñoz-Marí J., Zortea M., Blanes I., González-Ruiz V., Camps-Valls G., Plaza A., Serra-Sagrístà J., On the Impact of Lossy Compression on Hyperspectral Image Classification and Unmixing, *IEEE Geosci. Remote Sens. Lett.*, 2011, Vol. 8, No. 2, pp. 253–257.
15. Gualtieri J.A., Chettri S.R., Cromp R.F., Johnson L.F., Support Vector Machine Classifiers as Applied to AVIRIS Data, *Summaries of the Eighth JPL Airborne Earth Science Workshop*, Nevada, 1999, pp. 217–227.

16. Kim B.-J., Pearlman W.A., An embedded wavelet video coder using three-dimensional set partitioning in hierarchical trees (SPIHT), *Proc. of the Data Compression Conference, 1997 (DCC'97)*, Snowbird, 1997, pp. 251–260.
17. Kim B.-J., Xiong Z., Pearlman W.A., Low bit-rate scalable video coding with 3-D set partitioning in hierarchical trees (3-D SPIHT), *IEEE Trans. Circuits Syst. Video Technol.*, 2000, Vol. 10, No. 8, pp. 1374–1387.
18. Langevin Y., Forni O., Image and spectral image compression for four experiments on the ROSETTA and Mars Express missions of ESA, *Proc. SPIE. Applications of Digital Image Processing XXIII*, 2000, Vol. 4115, pp. 364–373.
19. Lee C., Choi E., Jeong T., Lee S., Lee J., Compression of hyperspectral images with discriminant features enhanced, *J. Appl. Remote Sens.*, 2010, Vol. 4, No. 1, pp. 041764.
20. Lee C., Youn S., Baek J.Y., Sagristà J.S., Effects of compression on classification performance and discriminant information preservation in remotely sensed data, *Proc. SPIE. Satellite Data Compression, Communications, and Processing XI*, 2015, Vol. 9501, pp. 950103.
21. Liang Z., Xinming T., Guo Z., Xiaoliang W. Effects of JPEG2000 and SPIHT Compression on Image Classification, *Proc. of the XXIst ISPRS Congress Technical Commission VII*, 2008, pp. 541–544.
22. Lim S., Sohn K., Lee C., Compression for hyperspectral images using three dimensional wavelet transform, *Proc. of the IEEE International Geoscience and Remote Sensing Symposium, 2001 (IGARSS 2001). Scanning the Present and Resolving the Future*, Sydney, 2001, pp. 109–111.
23. Liu X., Beltran J.F., Mohanchandra N., Toussaint G.T., On Speeding Up Support Vector Machines: Proximity Graphs Versus Random Sampling for Pre-Selection Condensation, *Intern. J. Computer, Electrical, Automation, Control and Information Engineering*, 2013, Vol. 7, No. 1, pp. 133–140.
24. *Lossless Multispectral and Hyperspectral Image Compression standard*. Green Book. Informational Report, Issue 1. CCSDS 120.2-G-1, Washington: The Consultative Committee for Space Data Systems, 2015, 99 p.
25. Markman D., Malah D., Hyperspectral image coding using 3D transforms, *Proc. of the International Conference on Image Processing, 2001 (ICIP 2001)*, Thessaloniki, 2001, Vol. 1, pp. 114–117.
26. Melgani F., Bruzzone L., Classification of Hyperspectral Remote Sensing Images With Support Vector Machines, *IEEE Trans. Geosci. Remote Sens.*, 2004, Vol. 42, No. 8, pp. 1778–1790.
27. Pearlman W.A., Said A., *Data compression using set partitioning in hierarchical trees*, Patent, 5764807 United States, 1998.
28. Penna B., Tillo T., Magli E., Olmo G., Transform Coding Techniques for Lossy Hyperspectral Data Compression, *IEEE Trans. Geosci. Remote Sens.*, 2007, Vol. 45, No. 5, pp. 1408–1421.
29. Qian S.-E., Hollinger A.B., Dutkiewicz M., Tsang H., Zwick H., Freemantle J.R., Effect of lossy vector quantization hyperspectral data compression on retrieval of red-edge indices, *IEEE Trans. Geosci. Remote Sens.*, 2001, Vol. 39, No. 7, pp. 1459–1470.
30. Said A., Pearlman W.A., A new, fast, and efficient image codec based on set partitioning in hierarchical trees, *IEEE Trans. Circuits Syst. Video Technol.*, 1996, Vol. 6, No. 3, pp. 243–250.
31. Serra-Sagristà J., Aulí-Llinàs F., Remote Sensing Data Compression, *Computational Intelligence for Remote Sensing Studies in Computational Intelligence*, Berlin, Heidelberg: Springer, 2008, pp. 27–61.
32. Shah C.A., Watanachaturaporn P., Varshney P.K., Arora M.K., Some recent results on hyperspectral image classification, *Proc. of the IEEE Workshop on Advances in Techniques for Analysis of Remotely Sensed Data, 2003 (WARSD 2003)*, Greenbelt, 2003, pp. 346–353.
33. Tang X., Cho S., Pearlman W.A., 3D set partitioning coding methods in hyperspectral image compression, *Proc. of the International Conference on Image Processing, 2003 (ICIP 2003)*, Barcelona, 2003, Vol. 2, pp. II-239–II-242.
34. Tang X., Pearlman W.A., Lossy-To-Lossless Block-Based Compression of Hyperspectral Volumetric Data, *Proc. of the International Conference on Image Processing, 2006 (ICIP 2006)*, Atlanta, 2006, pp. 1133–1136.
35. Vaiopoulos A.D., Developing Matlab scripts for image analysis and quality assessment, *Proc. SPIE. Earth Resources and Environmental Remote Sensing, GIS Applications II*, 2011, Vol. 8181, pp. 81810B.
36. van der Linden S., Rabe A., Held M., Jakimow B., Leitão P.J., Okujeni A., Schwieder M., Suess S., Hostert P., The EnMAP-Box — A Toolbox and Application Programming Interface for EnMAP Data Processing, *Remote Sens.*, 2015, Vol. 7, No. 9, pp. 11249–11266.
37. Vapnik V.N., *The Nature of Statistical Learning Theory*, New York: Springer Science & Business Media, 1995, 201 p.