

Нелинейное снижение размерности гиперспектральных данных на основе принципа сохранения дивергенции спектральной информации

Е.В. Мясников^{1,2}

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

²Институт систем обработки изображений РАН - филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

Аннотация. В работе предлагается нелинейный метод снижения размерности гиперспектральных данных, основанный на принципе сохранения дивергенции спектральной информации (SID). При этом дивергенция спектральной информации используется в качестве меры спектрального рассогласования как в исходном, так и в редуцированном пространстве. В рамках экспериментальных исследований, выполненных на открытых наборах гиперспектральных данных, решалась задача попиксельной классификации гиперспектральных изображений. Разработанный метод расширяет существующий инструментарий анализа гиперспектральных данных, позволяющий выполнять снижение размерности гиперспектральных данных на основе принципа сохранения заданных мер спектрального рассогласования.

1. Введение

Гиперспектральные изображения представляют собой трехмерный массив с двумя пространственными и одной спектральной размерностью. Гиперспектральные изображения регистрируются с использованием сенсоров высокого пространственного разрешения, вследствие чего каждый отсчет таких изображений представляет собой вектор, включающий в себя до нескольких сотен спектральных компонент.

Гиперспектральные изображения достаточно широко используются в различных областях деятельности. Их использование, с одной стороны, предоставляет новые возможности, позволяя извлекать информацию о материалах (компонентах), представленных на изображении, а с другой стороны, сопряжено с трудностями, обусловленными высокой спектральной размерностью. Вследствие этого важнейшей задачей становится устранение избыточности таких изображений при сохранении важной спектральной информации.

Для устранения избыточности наиболее часто используют линейные методы снижения размерности, такие как метод главных компонент (PCA) [1], осуществляющий поиск линейной проекции в подпространство меньшей размерности, максимизирующей разброс данных. В последние годы в рамках решения рассматриваемой задачи растет популярность нелинейных методов снижения размерности, таких как локально-линейное встраивание (Locally-linear embedding - LLE) [2], метод лапласианских собственных карт (Laplacian eigenmaps - LE) [3], метод локальных касательных пространств (Local Tangent Space Alignment - LTSA) [4],

изометрическое встраивание (ISOMAP) [5], анализ криволинейных компонент (Curvilinear component analysis – CCA), расстояний (Curvilinear distance analysis – CDA) [6] и нелинейное отображение (Nonlinear Mapping - NLM) [7].

Особый интерес при работе с нелинейными методами снижения размерности представляет возможность учета выбранных мер спектрального рассогласования. Хотя многие из указанных выше нелинейных методов позволяют учесть выбранную меру рассогласования во входном гиперспектральном пространстве (см., например, [8, 9, 10]), известно лишь несколько работ [11, 12], в которых производится попытка учесть выбранную меру рассогласования также и в выходном редуцированном пространстве. В обеих указанных работах в основу разрабатываемых методов положен принцип сохранения выбранных мер спектрального рассогласования. В работе [11] предложено несколько методов нелинейного отображения, основанных на принципе сохранения спектральных углов (SAM) [13]. В работе [12] в основе разрабатываемого метода лежит принцип сохранения мер спектральной корреляции [13].

Предлагаемый в настоящей работе метод строится по тем же принципам, что и в приведенных выше работах [11, 12]. Однако, в отличие от предыдущих работ, в основу метода положен принцип сохранения дивергенции спектральной информации (SID) [13]. Эта мера, наряду с мерами спектрального угла и спектральной корреляции, является одной из трех наиболее известных неевклидовых мер спектрального рассогласования в области анализа гиперспектральных данных и показывает высокие результаты при решении задач классификации гиперспектральных данных.

Работа организована следующим образом. В разделе 2 описываются основы разрабатываемого метода снижения размерности: вводится оценка качества снижения размерности и разрабатывается численная оптимизационная процедура, основанная на методе стохастического градиентного спуска. В разделе 3 описываются экспериментальные исследования. В этом разделе с использованием гиперспектральных изображений, находящихся в открытом доступе, предложенный метод сравнивается с альтернативными нелинейными методами снижения размерности, основанными на других мерах спектрального рассогласования. Эффективность предложенного подхода исследуется в терминах точности классификации. Работа завершается заключением в разделе 4 и списком используемой литературы в разделе 5.

2. Методы

Рассмотрим гиперспектральное изображение X , размером $W \times H$, содержащее M спектральных компонент. Каждый отсчет x_i , $i = 1..N$, $N = WH$ такого изображения можно рассматривать, как вектор в многомерном гиперспектральном пространстве R^M размерности M .

Как было сказано во введении, дивергенция спектральной информации (spectral information divergence - SID) является довольно популярной мерой в области анализа гиперспектральных изображений. Для пары векторов x_i и x_j эта мера задается следующим образом [13]:

$$SID(x_i, x_j) = D(x_i \| x_j) + D(x_j \| x_i),$$

$$D(x_i \| x_j) = \sum_{k=1}^M p_k(x_i) \log(p_k(x_i) / p_k(x_j)), \quad (1)$$

$$p_k(x_i) = \frac{x_{ik}}{\sum_{l=1}^M x_{il}}.$$

Здесь $p(x) = (p_1(x), \dots, p_M(x))^T$ рассматривается как функция распределения вероятностей дискретной случайной величины, порождаемая вектором x , а $D(x_i \| x_j)$ – усредненное по всем спектральным диапазонам различие собственной информации для вектора x_i по отношению к информации для вектора x_j (относительная энтропия). Отметим, что дивергенция спектральной информации (SID) является симметричной мерой по построению.

Предлагаемый в настоящей работе нелинейный метод снижения размерности гиперспектральных данных основан на принципе сохранения дивергенции спектральной информации между отсчетами гиперспектрального изображения.

Вначале каждому отсчету x_i , $i=1..N$ исходного изображения поставим в соответствие вектор y_i в редуцированном пространстве R^L меньшей размерности $L < M$. Далее введем следующую меру сохранения дивергенции спектральной информации:

$$\varepsilon = \mu \sum_{i,j=1(i<j)}^N (SID(x_i, x_j) - SID(y_i, y_j))^2, \quad (2)$$

показывающую, насколько хорошо попарные меры спектрального рассогласования между отсчетами гиперспектрального изображения сохраняются в пространстве меньшей размерности.

В приведенном выше выражении (2) множитель μ принимается постоянным для заданного изображения X и в настоящей работе рассчитывается как

$$\mu = \left(\sum_{i,j=1(i<j)}^N SID^2(x_i, x_j) \right)^{-1}.$$

Формально задача снижения размерности может быть поставлена, как задача минимизации функционала ошибки (2) по всевозможным значениям параметров, представляющих собой координаты векторов (отсчетов изображения) в редуцированном пространстве $Y = \{y_i, i = 1..N\}$. Решение задачи минимизации может быть выполнено по аналогии с работами [11, 12, 14] с использованием методов стохастического градиентного спуска. При таком подходе истинное значение $\nabla \varepsilon$ градиента в процедуре градиентного спуска

$$Y(t) = Y(t-1) - \alpha \nabla \varepsilon \quad (3)$$

аппроксимируется на каждой итерации процедуры с использованием подмножества, состоящего из R случайно выбранных векторов $\{y_{r_j}, j = 1..R\}$, где r_j – случайные индексы.

Реализация такой схемы оптимизации требует нахождения частных производных функционала ошибки (2):

$$\frac{\partial \varepsilon}{\partial y_{ik}} = -2\mu \sum_{i,j=1(i<j)}^N (SID(x_i, x_j) - SID(y_i, y_j)) \frac{\partial}{\partial y_{ik}} SID(y_i, y_j)$$

и меры рассогласования (1):

$$\frac{\partial}{\partial y_{ik}} SID(y_i, y_j) = \frac{1}{\sum_{l=1}^L y_{il}} \left(1 - s_{ij} - \frac{p_k(y_j)}{p_k(y_i)} + \log \frac{p_k(y_i)}{p_k(y_j)} \right),$$

где

$$s_{ij} = \sum_{l=1}^L \left(p_l(y_i) + p_l(y_i) \log \frac{p_l(y_i)}{p_l(y_j)} - p_l(y_j) \right).$$

Окончательное рекуррентное соотношение, позволяющее уточнять координаты векторов y_i , $i=1..N$ в редуцированном спектральном пространстве, выглядит следующим образом:

$$y_{ik}(t) = y_{ik}(t-1) + 2\alpha\mu \sum_{j=1}^R \frac{SID(x_i, x_{r_j}) - SID(y_i, y_{r_j})}{\sum_{l=1}^L y_{il}} \left(1 - s_{ir_j} - \frac{p_k(y_{r_j})}{p_k(y_i)} + \log \frac{p_k(y_i)}{p_k(y_{r_j})} \right). \quad (4)$$

3. Эксперименты

В настоящем разделе описываются результаты экспериментального сравнения разработанного метода с альтернативными методами. Для проведения экспериментов мы использовали две хорошо известные гиперспектральные сцены [14], имеющие данные попиксельной истинной классификации: Indian pines и Kennedy space center. Оба гиперспектральных изображения получены с использованием сенсора AVIRIS.

Первая сцена содержит 145×145 отсчетов в 224 спектральных диапазонах. В экспериментах использовался вариант, содержащий 204 спектральных канала, в котором некоторые спектральные каналы были исключены в связи с высоким уровнем шума. Классифицированные отсчеты изображения разделены на 16 классов.

Изображение Kennedy space center содержит 512×614 пикселей. В экспериментах использовалась версия, содержащая 176 спектральных диапазонов. Изображение с истинной классификацией содержит информацию только об относительно небольшом количестве пикселей, которые разделены на 13 классов.

В рамках экспериментов была произведена попиксельная классификация указанных изображений с использованием двухэтапного подхода, при котором на первом этапе выполнялось снижение размерности, а на втором – собственно классификация с использованием описаний (признаков), полученных на первом этапе. Описываемые ниже экспериментальные исследования отражают результаты, полученные как с использованием разработанного метода снижения размерности, так и с использованием аналогичных методов, построенных на основе различных мер спектрального рассогласования. В частности, на этапе снижения размерности использовался метод нелинейного отображения, основанный на евклидовом расстоянии (NLM), метод, основанный на аппроксимации спектральных углов евклидовыми расстояниями (SAED), метод, основанный на сохранении спектральной корреляции (SCPM), а также разработанный метод, основанный на сохранении дивергенции спектральной информации (SDPM).

На этапе классификации использовались 1-NN классификаторы по ближайшему соседу соответствующие используемым методам снижения размерности. Для методов NLM и SAED, в которых рассогласование между выходными векторами рассчитывалось как евклидово расстояние, использовался 1-NN классификатор, основанный на евклидовом расстоянии. Для метода SCPM, использовался 1-NN с мерой близости, равной разности между единицей и коэффициентом корреляции Пирсона. Для разработанного метода SDPM в качестве меры в 1-NN классификаторе использовалась дивергенция спектральной информации (SID).

При выполнении экспериментов вначале применялась маска истинной классификации, после чего для отобранного множества отсчетов с известной попиксельной классификацией выполнялось снижение размерности. Выходная размерность изменялась в диапазоне $m=3, 5, 10, \dots, 30$, и для каждой выходной размерности измерялось качество классификации.

В качестве меры качества попиксельной классификации использовалась точность классификации (CA), определяемая как доля верно классифицированных отсчетов из общего числа классифицируемых отсчетов. Результаты выполненных экспериментов представлены ниже.

Как видно из результатов экспериментов, лучшее качество классификации показывали два метода: метод, основанный на спектральных углах (SAED), а также разработанный метод, основанный на сохранении спектральной дивергенции (SDPM). Предложенный метод показал сравнимое или лучшее качество классификации в большинстве представленных случаев для размерности не менее $m=10$. Наихудшие результаты были показаны методом SCPM для малых размерностей выходного пространства.

4. Приложения

В работе предложен и исследован нелинейный метод снижения размерности гиперспектральных данных (SDPM), действие которого основано на сохранении дивергенции спектральной информации (SID). Проведенные эксперименты показали, что по сравнению с другими исследованными методами, применение разработанного метода позволяет получить сравнимое или лучшее качество попиксельной классификации для размерностей выходного пространства не менее $m=10$.

В целом, разработанный метод расширяет существующий инструментарий анализа гиперспектральных данных, позволяющий выполнять снижение размерности гиперспектральных данных на основе принципа сохранения заданных мер спектрального рассогласования.




Рисунок 5. Зависимость точности классификации (CA) от размерности редуцированного пространства (m) для различных методов снижения размерности: гиперспектральное изображение Indian Pines (вверху) и Kennedy Space Center (внизу).

5. Литература

- [1] Richards, J.A. Remote Sensing Digital Image Analysis: An Introduction / J.A. Richards, X. Jia, D.E. Ricken, W. Gessner. – Springer-Verlag, New York, Inc., 1999.
- [2] Roweis, S.T. Nonlinear Dimensionality Reduction by Locally Linear Embedding / S.T. Roweis, L.K. Saul // Science. – 2000. – Vol. 290. – P. 2323-2326.
- [3] Belkin, M. Laplacian Eigenmaps and Spectral Techniques for Embedding and Clustering / M. Belkin, P. Niyogi // Advances in Neural Information Processing Systems. – 2001. – Vol. 14. – P. 586-691.
- [4] Zhang, Zh. Principal Manifolds and Nonlinear Dimension Reduction via Local Tangent Space Alignment / Zh. Zhang, Zh. Hongyuan // SIAM Journal on Scientific Computing. – 2005. – Vol. 26(1). – P. 313-338.
- [5] Tenenbaum, J.B. A Global Geometric Framework for Nonlinear Dimensionality Reduction / J.B. Tenenbaum, V. de Silva, J.C. Langford // Science. – 2000. – Vol. 290. – P. 2319-2323.
- [6] Demartines, P. Curvilinear Component Analysis: A Self-Organizing Neural Network for Nonlinear Mapping of Data Sets / P. Demartines, J. Héroult // IEEE Transactions on Neural Networks. – 1997. – Vol. 8(1). – P. 148-154.
- [7] Sammon Jr., J.W. A nonlinear mapping for data structure analysis / J.W. Sammon Jr. // IEEE Trans. Comput. – 1969. – Vol. 18(5). – P. 401-409.
- [8] Bachmann, C.M. Exploiting manifold geometry in hyperspectral imagery / C.M. Bachmann, T.L. Ainsworth, R.A. Fusina // IEEE Trans. Geosci. Remote Sens. – 2005. – Vol. 43(3). – P. 441-454.
- [9] Ding, L. Dimensionality reduction and classification for hyperspectral remote sensing data using ISOMAP / L. Ding, P. Tang, H. Li // Hongwai yu Jiguang Gongcheng / Infrared and Laser Engineering. – 2013. – Vol. 6(10). – P. 2707-2711.
- [10] Du, P. Dimensionality reduction and feature extraction from hyperspectral remote sensing imagery based on manifold learning / P. Du, X. Wang, K. Tan, J. Xia // Wuhan Daxue Xuebao

- (Xinxi Kexue Ban). Geomatics and Information Science of Wuhan University. – 2011. – Vol. 36(2). – P. 148-152.
- [11] Myasnikov, E. Nonlinear Mapping Based on Spectral Angle Preserving Principle for Hyperspectral Image Analysis / E. Myasnikov, M. Felsberg, A. Heyden, N. Krüger (eds) // Computer Analysis of Images and Patterns. Lecture Notes in Computer Science. – 2017. – Vol. 10425. – P. 416-427.
- [12] Myasnikov, E. Nonlinear Dimensionality Reduction of Hyperspectral Data Using Spectral Correlation as a Similarity Measure / E. Myasnikov // Analysis of Images, Social Networks and Texts. AIST 2017. Lecture Notes in Computer Science. – 2018. – Vol. 10716. – P. 237-244.
- [13] Chang, C.-I. Hyperspectral Data Processing: Algorithm Design and Analysis / C.-I. Chang // John Wiley & Sons, 2013. – 1164 p.
- [14] Myasnikov, E. Evaluation of Stochastic Gradient Descent Methods for Nonlinear Mapping of Hyperspectral Data / E. Myasnikov // Image Analysis and Recognition. ICIAR 2016. Lecture Notes in Computer Science. – 2016. – Vol. 9730. – P. 276-283.
- [15] Hyperspectral Remote Sensing Scenes [Electronic resource]. – Access mode: [http://www.ehu.es/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](http://www.ehu.es/ccwintco/index.php?title=Hyperspectral%20Remote%20Sensing%20Scenes) (01.11.2017).

Благодарности

Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 18-07-01312-а.

Nonlinear dimensionality reduction of hyperspectral data based on spectral information divergence preserving principle

E.V. Myasnikov^{1,2}

¹Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

²Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

Abstract. The paper proposes a nonlinear dimensionality reduction technique for hyperspectral data based on the principle of preserving the spectral information divergence (SID). In this technique, the spectral information divergence is used as a spectral dissimilarity measure in both the original and reduced space. In the experimental studies performed using open hyperspectral images, the problem of per pixel classification of hyperspectral images was solved. The developed method extends the existing hyperspectral data analysis toolkit, which allows to reduce the dimensionality of hyperspectral data based on the principle of preserving specified spectral dissimilarity measures.