Методы анализа данных дистанционного зондирования Земли

Н.П. Лаверов¹, В.В. Попович², Л.А. Ведешин³, Ф.Р. Гальяно⁴

¹ Институт геологии рудных месторождений, петрографии, минералогии и геохимии РАН Москва, 119017, Россия E-mail: laverov@igem.ru ² Санкт-Петербургский институт информатики и автоматизации РАН Санкт-Петербург, 199178, Россия E-mail: popovich@oogis.ru ³ Институт космических исследований РАН, Москва, 117997, Россия E-mail: vedeshin40@mail.ru ⁴ ЗАО «СПИИРАН-НТБВТ», Санкт-Петербург, 199178, Россия E-mail: galiano@oogis.ru

В статье рассмотрены методы анализа данных дистанционного зондирования (Земли) – ДДЗ. Актуальность разработки данных методов обусловлена острой необходимостью глубокой автоматизации процесса обработки ДДЗ для их оперативного использования при решении самых различных задач: мониторинг природных ресурсов, борьба с морским пиратством, пожарами и другими стихийными бедствиями, управление бизнесом, мегаполисом и целый ряд других актуальных задач. Описывается модифицированный метод анализа ДДЗ на основе SVD, позволяющий повысить точность классификации. Теоретические результаты подтверждены компьютерными экспериментами и практической реализацией в системе анализа ДДЗ.

Ключевые слова: данные дистанционного зондирования, классификация, сингулярное разложение матриц

Введение

Применение искусственных спутников Земли развивается стремительными темпами. Вместе с тем широкое применение данных спутникового зондирования формирует целое множество новых задач, требующих решения. Очевидным примером таких задач является оперативный анализ ДДЗ. На основе типовых методов автоматизации данный анализ не может быть эффективен, т.к. требует огромных человеческих ресурсов, что обуславливает высокую цену такого анализа и недопустимые временные задержки. Системы анализа ДДЗ требуют интеграции различных алгоритмов, в частности, обработки изображений и распознавания образов.

Для улучшения результатов классификации и повышения быстродействия анализа используются предварительные преобразования пространства признаков. В частности, расчет сингулярного разложения матрицы (англ. Singular Value Decomposition, SVD), составленной из обучающих векторов, позволяет уменьшить размерность пространства признаков, что позволяет снизить требования к вычислительным ресурсам (Tarakanov, Skormin, Sokolova, 2003). Однако при SVD-классификации затруднены как учет информации о значимости отдельных признаков объекта, так и разница в цене ошибки классификации (англ. misclassification cost) при решении различных задач.

Целью работы является усовершенствование алгоритмов анализа ДДЗ на основе SVD с целью повышения качества анализа путем изменения соотношения ошибок первого и второго рода в результатах классификации и вклада каждого признака объекта в ее результат. Используемые формальные критерии оценки качества алгоритмов приведены далее.

Для решения практических задач невозможно применение единственного алгоритма. Для автоматизации анализа различных типов ДДЗ с различными целями необходимо разработать системы алгоритмов с унифицированными интерфейсами взаимодействия. Такой подход позволяет гибко адаптировать систему к особенностям предметной области без ограничения общности используемых алгоритмов.

Классификация участков поверхности Земли

Типичной целью анализа ДДЗ является определение класса определенного участка поверхности Земли или атмосферы, исходя из величины его отражающей способности в различных спектральных диапазонах (Storvik, Fjortoft, Solberg, 2005). Задача может быть сформулирована следующим образом. Пусть задано отображение исходных ДДЗ в векторах вещественных чисел одинаковой размерности. При этом векторы признаков участков земной поверхности составлены из числовых значений пикселей, обладающих одинаковыми координатами в рамках каждого спектрального диапазона мультиспектрального изображения. Под *образом* понимается п-мерный вектор столбец $X = [x_1, ..., x_j, ..., x_n]^T$, где x_i – вещественные числа (*признаки* образа X) и T – символ матричного транспонирования. Величины x_i отражают яркость определенных участков земной поверхности или атмосферы в заданном спектральном диапазоне с номером i.

Из векторов признаков может быть сформирована матрица вещественных чисел A размерностью $m \times n$. Известно, что любую матрицу, используя сингулярное разложение матрицы (SVD), можно представить в виде:

$$A = \sum_{\nu=1}^{h} s_{\nu} L_{\nu} R_{\nu}^{T},$$

где s_v – сингулярные числа, L_v – левые сингулярные вектора, R_v – правые сингулярные вектора, а h – минимальное из чисел m и n. При этом слагаемые ряда упорядочены по убыванию сингулярных чисел и учтены дополнительные ограничения на элементы ряда. Чем длиннее ряд, тем выше точность разложения.

Традиционный алгоритм SVD классификации (Тагаkanov, Skormin, Sokolova, 2003) состоит из этапов обучения и распознавания. Из векторов признаков формируется матрица A, для которой вычисляются первые g членов сингулярного разложения, $g \le h$. Таким образом, происходит существенное снижение размерности и объема данных. Полученные в результате наборы троек, состоящие из сингулярного числа и соответствующих ему левого, а также правого сингулярного вектора, есть результат обучения. Количество таких троек определяет размерность нового пространства признаков. Процесс распознавания сводится к отображению классифицируемого вектора в новое пространство признаков и поиска наиболее близкого ему элемента. Для учета нелинейных зависимостей между исходными данными и возможными классами возможет учет весов признаков и классов, как описано ниже.

Варьируя веса классов возможно изменять соотношение ошибок первого и второго рода в результатах классификации; веса признаков позволяют задавать вклад отдельного признака в вычисление параметров пространства признаков меньшей размерности и в вычисление ближайшего соседа в новом пространстве. Веса могут задаваться экспертами, исходя из понимания предметной области, или могут быть подобраны на основе известных методов поиска экстремума, исходя из критерия минимизации ошибок классификации. SVD классификация выбрана в качестве основы, поскольку, с одной стороны, скорость его работы достаточно велика (при использовании быстрых алгоритмов SVD разложения (Golub, Van Loan, 1996)), а, с другой стороны, он не накладывает ограничений на используемую меру близости при классификации, что позволяет использовать меру, наиболее релевантную текущей задаче.

Модифицированный алгоритм в дальнейшем называется Modified SVD (MSVD), более подробно он описан, например, в (Гальяно, 2010).

Математическая формулировка задачи

Определим распознавание образов как отображение $\{X\} \rightarrow \{C\}$, где $\{X\}$ – множество всех образов, $\{C\}$ – множество всех классов, заданных их метками с₁,...,с_n. Дано:

- набор из т обучающих образов X_i, j=1,...,m;
- для каждого признака каждого обучающего образа задан интервал допустимых значений x_i ∈ [a_i; b_i], a_i ∈ R, b_i ∈ R, b_i > a_i, i = 1,...,n, который считается общим для всех признаков с одинаковым номером по всем обучающим образам X_i;
- для каждого обучающего образа X_j соответствующий ему элемент множества классов {C_l}^u_{t=1};
- для каждого класса обучающего образа его вес $\beta_t \in [0,1], t=1,...,u;$
- для каждого признака всех обучающих образов его вес $\gamma_i \in [0,1]$, i=1,...,n;
- произвольный п-мерный вектор Z.

Необходимо найти класс вектора Z с учетом заданных весов признаков и классов.

Алгоритм обучения MSVD

Алгоритм обучения системы классификации для решения этой задачи может быть представлен в виде следующей последовательности шагов:

 масштабирование интервала допустимых значений всех признаков x_i, i=1,...,n на общую для всех признаков шкалу [0;b^{*}] с использованием следующей формулы (здесь x^{*} – значение нормированного признака)¹:

$$x_{i}^{*} = \frac{(x_{i} - a_{i})b_{i}^{*}}{b_{i} - a_{i}}x_{i}, \ b_{i}^{*} = \min_{i}b;$$

умножение каждого признака на его вес γ;

Если диапазон значений яркостей анализируемых растров одинаков, то данный этап можно опустить.

- формирование обучающей матрицы $A = [X_1, ..., X_m]^T$ размерности $m \times n$;
- вычисление максимального сингулярного числа s, а также левого и правого сингулярных векторов L и R обучающей матрицы по любому из стандартных алгоритмов SVD-разложения (см. напр. (Golub, Van Loan, 1996));
- хранить первые g сингулярных чисел s и соответствующие им сингулярные вектора L и R.

Алгоритм классификации MSVD

Распознавание вектора признаков осуществляется в соответствии с алгоритмом:

- масштабирование значения всех признаков образа *Z* и умножение их на вес согласно первым двум этапа обучения;
- для введенного вектора *P* вычисление w_v(P) (координат проекции вектора в новое пространство признаков): w_v(P)=(P^TR_v)/s_v, v=1...g;
- для каждого j=1,...,т вычисление² евклидового расстояния P_j, здесь [l_j]_v j-я компонента левого сингулярного вектора L_v:

$$P_{j} = \sqrt{\sum_{\nu=1}^{g} \left(w_{\nu} - \left[l_{j} \right]_{\nu} \right)^{2}};$$

- для всех j=1,...,m нормирование значений P_j: d_j=P_j/M, M максимальное значение из всех P_j;
- поиск j^{*} среди всех j=1,...,m индекса, при котором величина d_jβ_t минимальна, где β_t – вес класса, соответствующего обучающему образу X_i;
- считать класс образа X_i* искомым классом образа Z.

Рассмотрим примеры анализа реальных ДДЗ с помощью, в том числе, и описанных выше алгоритмов.

Результаты компьютерных экспериментов

Алгоритмы анализа являются частью разработанной системы анализа ДДЗ. Программная реализация распределенной системы анализа ДДЗ включает в себя следующие компоненты: серверы анализа и хранения данных, система получения ДДЗ и ГИС-интерфейс.

В качестве примера выделения рассмотрим задачу выделения облачности. Графическое представление процесса выделения облачности приведено на *puc. 1*, а результат – на *puc. 2*.

Процесс анализа состоит из стадий предварительной обработки, классификации каждого спектрального диапазона и объединения полученных результатов. Предварительная обработка состоит из стадий медианной фильтрации, изменения цветового пространства и

² В данном случае использование евклидового расстояния необязательно; допустимо использование других норм, если это приводит к улучшению результатов классификации.

сегментации на основе алгоритмов, описанных в (Харинов, 2006, 2008). Для хранения данных о сегментации использованы динамические деревья (Tarjan, 1983; Sleator, Tarjan, 1985). Более подробно структура аналогичного процесса описана в (Харинов, Гальяно, 2009).



Рис. 1. Графическое представление процесса выделения облачности



Рис. 2. Пример анализа ДДЗ с целью выделения облачности. Сверху – исходные данные, используемые для выделения облачности; снизу – результат анализа. Исходные данные предоставлены СКАНЕКС, http://www.scanex.ru. Желтым цветом обозначены правильно классифицированные пиксели, красным – пропуски объектов, зеленым – ложные срабатывания

Процесс сложен из элементов, образующих палитру алгоритмов, при этом для выделения других объектов требуется лишь собрать другой набор элементов палитры и задать связи между ними и их параметры при помощи графического редактора. Для решения этой задачи MSVD не использовался. Палитра включает, в частности, SRM (Nock, Nielsen, 2004) и алгоритм на основе модели Мамфорда-Шаха (Robinson, Redding, Crisp, 2002).

Для оценки точности полученных результатов применяются следующие показатели. Пусть α – количество объектов на исследуемых изображениях, правильно классифицированных как принадлежащих заданному классу, γ – количество объектов на исследуемых изображениях, неверно классифицированных как принадлежащих заданному классу, β – количество реально имеющихся на изображениях объектов заданного класса. Здесь $\alpha < \beta$. Тогда показателями, позволяющими оценивать оптимальность выполнения операции классификации, являются:

- вероятность правильного обнаружения объекта заданного класса: $P_r = \alpha / \beta$;
- доля ошибок классификации, т.е. отношение³: $K_e = (\gamma + \alpha) / \beta$.

По результатам проведенного вычислительного эксперимента установлено, что для данных имеющихся данных при выделении облачности $P_r \ge 0.85$, $K_e \le 0.2$.

Другой пример анализа ДДЗ – задача разделения пикселей изображения на 2 класса – водной поверхности и суши. Задача решалась с использованием MSVD. Векторы признаков размерностью 3 составлялись непосредственно из яркостей пикселей с одинаковыми координатами. Результат сравнения классификации с единичными весами классов β, и с весами 1 и 0,25 для земли и суши соответственно, приведены на *рис. 3*. Анализ этих результатов показывает, что учет весов позволяет уменьшить число ошибок. Так, при традиционном алгоритме классификации, основанном на SVD, процент неправильных решений составил 32,34%, а для MSVD – всего лишь 20,79%. Таким образом, полученные результаты позволяют сделать вывод о расширении возможностей MSVD-классификации по сравнению с SVD.



Рис. 3. Слева направо: исходные данные, результаты классификации с единичными весами классов (слева) и с весами классов, равными 1 и 0,25 (справа). Метками классов выступают яркости пикселей (0 для водной поверхности и 255 для суши). Изображения из базы университета Южной Калифорнии (база данных изображений USC-SIPI, http://sipi.usc.edu/database/)

³ Очевидно, что та же величина может быть выражена в процентах. Здесь и далее показатели классификации оценивались по отношению к эталонной классификации того же растра, выполненной человеком.

Сравнительно низкое качество классификации в данном случае обусловлено использованием малого объема обучающей выборки и применение MSVD классификации к исходному изображению без его предварительной обработки.

Таким образом, показано, что MSVD позволяет повысить точность классификации и компенсировать погрешности при формировании обучающих выборок, а также варьировать соотношение ошибок первого и второго рода при классификации. Полученные результаты могут найти применение при классификации данных большой размерности (поскольку SVD позволяет эффективно ее снижать), характеризующихся нелинейными зависимостями между исходными данными и результатом классификации. Нелинейные зависимости могут быть учтены, поскольку используемый при классификации в новом пространстве признаков метод ближайшего соседа в состоянии строить разделяющие поверхности произвольной формы.



Рис. 4. Пример анализа ДДЗ с целью выделения судов. Слева визуализация исходных данных, используемых для выделения судов; справа результат анализа – обнаруженные суда и визуализация их курсов. Исходные данные предоставлены СКАНЕКС

Заключение

Описанные выше алгоритмы анализа позволяют решать широкий спектр различных задач и учитывать набор различных признаков искомых объектов. Однако для достижения максимальной эффективности процесса анализа требуется привлечение высококвалифицированного эксперта, владеющего информацией о предметной области, не сводящейся к обучающей выборке.

Необходимость учета разнообразных свойств искомых объектов не позволяет ограничиваться единственным алгоритмом сегментации и описания ДДЗ (Aksoy, Chen, 2006; Galjano, Popovich, 2007), однако единообразное представление свойств объектов в виде вектора признаков позволяет учесть весь набор релевантных признаков при классификации. Те-

кущий уровень разработок позволяет создавать системы, существенно облегчающие и ускоряющие работу эксперта, однако создание автоматической системы анализа ДДЗ, сочетающей универсальность с эффективностью находится за пределами сегодняшних возможностей.

Литература

- 1. Гальяно Ф.Р. Алгоритм классификации участков поверхности Земли на основе сингулярного разложения матриц. «Информационные технологии». 2010. № 12. С. 35–37. *Харинов М.* Запоминание и адаптивная обработка информации цифровых изображений. СПб.: Издатель-
- 2. ство Санкт-Петербургского университета, 2006. 138 с.
- Харинов М.В. Адаптивное встраивание водяных знаков по нескольким каналам: Патент 2329522 РФ. 3. 20.07.2008. Бюл. № 20. 41 с.
- Харинов М.В., Гальяно Ф.Р. Распознавание изображений посредством представлений в различном числе 4. градаций // Сборник докладов четырнадцатой Всероссийской конференции «Математические методы распознавания образов». М.: МАКС Пресс, 2009. С. 465–468.
- Aksoy S., Chen C.H. Spatial Techniques for Image Classification // Signal and Image Processing for Remote Sensing. Boca Raton: Taylor & Francis, 2006. P. 491–513. Galjano Ph., Popovich V. Intelligent Images Analysis in GIS // Proceedings of IF&GIS-2007. Berlin: Springer, 5.
- 6. 2007. P. 325.
- Golub G.H., Van Loan C.F. Matrix Computations. Baltimore: Johns Hopkins University Press, 1996. 728 p. 7
- Nock R., Nielsen F. Statistical Region Merging // IEEE Transactions on Pattern Analysis and Machine Intelli-gence. 2004. No. 11. P. 1–7. Robinson D.J., Redding N.J., Crisp D.J. Implementation of a fast algorithm for segmenting SAR imagery. Edin-8
- 9 burgh: DSTO Electronics and Surveillance Research Laboratory, 2002. P. 41.
- Sleator D.D., Tarjan R.E. Self-Adjusting Binary Search Trees // Journal of the ACM. 1985. Vol. 32. No. 3. P. 652–686.
 Storvik G., Fjortoft R., Solberg A.H.S. A Bayesian approach to classification of multiresolution remote sensing data // IEEE Trans. Geosci. Rem. Sens. 2005. Vol. 43. No. 3. P. 539–547.
- 12. Tarakanov A.O., Skormin V.A., Sokolova S.P. Immunocomputing: Principles and applications. New York: Springer, 2003. 230 p.
- 13. Tarjan R.E. A Data Structure for Dynamic Trees // Journal of Computer and System Sciences. 1983. Vol. 26. No. 3. P. 362–391.

Methods of Earth remote sensing data analysis

N.P. Laverov¹, V.V. Popovich², L.A. Vedeshin³, F.R. Galiano⁴

¹Institute of Geology of Ore Deposits, Petrography, Mineralogy and Geochemistry RAS Moscow 119017, Russia *E-mail: laverov@jgem.ru* ² St.Petersburg Institute for Informatics and Automation RAS Saint Petersburg 199178, Russia *E-mail: popovich@oogis.ru* ³ Space Research Institute RAS, Moscow 117997, Russia

E-mail: vedeshin40@mail.ru

⁴ SPIIRAS-HTR&DO Ltd, Saint Petersburg 199178, Russia

E-mail: galiano@oogis.ru

The article describes the methods of analysis of Earth remote sensing data – RSD. The urgency of the development of these methods is due to the pressing need to automate the process of deep processing of remote sensing data for operational use in solving a wide variety of tasks: monitoring of natural resources, fight against sea piracy, fires and other natural disasters, management of business or megalopolis and many of other actual tasks. A modified method that increases efficiency of RSD analysis based on SVD is proposed. Theoretical results are confirmed with computer experiments and practical realization in RSD analysis system.

Keywords: remote sensing data, image processing, segmentation and classification, singular value decomposition

References

- Gal'yano F.R. Algoritm klassifikacii uchastkov poverhnosti zemli na osnove singulyarnogo razlozheniya matric. 1. (Algorithm of Earth's surface classification) *Informatsionnye tekhnologii*, No. 12, 2010, pp. 35–37. Kharinov, M. *Zapominanie i adaptivnaya obrabotka informatsii tsifrovykh izobrazhenii* (Storing and adaptive
- 2. information processing of digital images), Saint-Petersburg: Izd. SPbU, 2006, 138 p.
- Kharinov M.V. Adaptivnoe vstraivanie vodyanykh znakov po neskol'kim kanalam (Adaptive embedding of 3. watermarks by multiple channels): Patent 2329522 RF, 20.07.2008, No. 20, 41 p.
- 4. Kharinov M.V., Gal'yano F.R. Raspoznavanie izobrazhenii posredstvom predstavlenii v razlichnom chisle gradatsii (Images recognition by means of its representation in different number of gradations), 14 Konf. Matematicheskie metody raspoznavaniya obrazov (14 Conf. Mathematical Methods of Pattern Recognition), Proc. Conf., Moscow: MAKS Press, 2009, pp. 465-468
- Aksoy S., Chen C.H. Spatial Techniques for Image Classification, In: Signal and Image Processing for Remote Sensing, Boca Raton: Taylor & Francis, 2006, pp. 491–513. 5
- Galjano Ph., Popovich V. Intelligent Images Analysis in GIS, Proc. IF&GIS-2007, Berlin: Springer, 2007, 325 p. 6
- Golub G.H., Van Loan C.F. Matrix Computations, Baltimore: Johns Hopkins University Press, 1996, p. 728. 7
- Nock R., Nielsen F. Statistical Region Merging, IEEE Transactions on Pattern Analysis and Machine Intelligence, 8. 2004, No. 11, pp. 1-7.
- Robinson, D.J., Redding, N.J., Crisp, D.J. *Implementation of a fast algorithm for segmenting SAR imagery*, Edinburgh: DSTO Electronics and Surveillance Research Laboratory, 2002, 41 p. 9.
- 10. Sleator D.D., Tarjan R.E. Self-Adjusting Binary Search Trees, Journal of the ACM, 1985, Vol. 32, No. 3,
- pp. 652–686.
 Storvik G., Fjortoft R., Solberg A.H.S. A Bayesian approach to classification of multiresolution remote sensing data, *IEEE Transactions on Geoscience and Remote Sensing*, 2005, Vol. 43, Issue 3, pp. 539–547.
- Tarakanov A.O., Skormin V.A., Sokolova S.P. Immunocomputing: Principles and applications, New York: Springer, 2003, 230 p.
- 13. Tarjan R.E. A Data Structure for Dynamic Trees, Journal of Computer and System Sciences, 1983, Vol. 26, No. 3, pp. 362-391.