

РАЗРАБОТКА И ИССЛЕДОВАНИЕ АЛГОРИТМА КЛАССИФИКАЦИИ НА ОСНОВЕ МЕТОДА ОПОРНЫХ ПЛОСКОСТЕЙ

Е.В. Гошин¹, Г.Е. Лошкарева¹, В.А. Фурсов^{1,2}

¹Самарский государственный аэрокосмический университет им. академика С.П. Королёва
(национально исследовательский университет)

²Институт систем обработки изображений РАН

Разрабатывается и исследуется алгоритм классификации гиперспектральных изображений, основанный на методе опорных плоскостей с использованием показателя сопряженности. Предлагается новая процедура формирования опорных плоскостей. Обучение векторов осуществляется с использованием векторов, не принадлежащих «своему» классу. Приводятся результаты экспериментов на тестовом изображении.

Введение

Тематическая классификация гиперспектральных изображений в последние годы набирает все большую популярность. Задачи дистанционного зондирования земли являются перспективным направлением в развитии информационных технологий, используются в сельском хозяйстве, минералогии, физике и системах наблюдения, криминалистике и др. Дистанционное зондирование поверхности земли позволяет отслеживать урожайность земель, наблюдать за ситуацией с лесными пожарами, за строительством дорог и различных объектов и др.

Для решения указанных выше задач наиболее широко используются алгоритмы тематической классификации, основанные на методах спектрального угла и опорных векторов(SVM). В данной работе представлен алгоритм классификации, основанный на методе опорных плоскостей с использованием показателя сопряженности.

Постановка задачи

Исходным является гиперспектральное изображение, полученное при дистанционном зондировании Земли [1]. Оно представляет из себя куб данных (обозначим координатами X, Y, Z), включающий в себя пространственную информацию (X, Y) об изображении, которая дополнена спектральной информацией (Z) по каждой пространственной координате. Требуется найти заданный объект на изображении.

Предполагается, что по пространственным координатам гиперспектральное изображение может быть разбито на K классов. К каждому классу относится некоторый тип объекта (например, поля кукурузы, пшеницы, дороги и др.).

Описание алгоритма классификации

Для описания алгоритма рассмотрим k -ый класс. В этом классе выберем опорную плоскость \mathbf{X}_k [2], состоящую из пары гипервекторов этого класса. Для выбранной опорной плоскости k -ого класса показатель сопряженности [3] с векторами из класса $n \neq k$ может быть рассчитан по следующей формуле:

$$\mathbf{R}_k(j) = \frac{\mathbf{x}_j^T \mathbf{Q}_k \mathbf{x}_j}{\mathbf{x}_j^T \mathbf{x}_j},$$

где $\mathbf{Q}_k = \mathbf{X}_k [\mathbf{X}_k^T \mathbf{X}_k]^{-1} \mathbf{X}_k^T$, \mathbf{x}_j – вектор j из класса $n \neq k$, $j = 1, \dots, N_n$. Таким образом, для N_n векторов имеем N_n значений \mathbf{R}_k . Для полученных \mathbf{R}_k определяем среднеквадратическое значение

$$\mathbf{R}_{mean}(n) = \sqrt{\frac{(\mathbf{R}_j)^2}{N_n}},$$

где $n = (1, \dots, K) \setminus k$. Далее, то же проделываем с оставшимися классами. Получаем $K - 1$ значений \mathbf{R}_{mean} и снова рассчитываем среднеквадратическое

$$\mathbf{R}(i) = \sqrt{\frac{(\mathbf{R}_{mean}(n))^2}{K-1}},$$

где $n = (1, \dots, K) \setminus k$, $i = 1, \dots, C_{N_n}^2$.

Далее аналогичным образом определяем показатели сопряженности для всех плоскостей \mathbf{X}_k из k -ого класса и получаем $C_{N_n}^2$ значений $\mathbf{R}(i)$, где $i = 1, \dots, C_{N_n}^2$. Среди них ищем минимальное

$$R = \min_{i=1, C_{N_n}^2} \mathbf{R}(i)$$

Данные о гиперплоскости, которой соответствует полученное значение R , сохраняются. Обозначим их как \mathbf{Y}_k . Таким образом, мы получаем опорную плоскость, значение показателя сопряженности для которой наиболее удалено от класса, которому она принадлежит. В результате определяется плоскость, которая будет эффективно распознавать свой класс. Вместе с тем, она будет менее чувствительна к гипервекторам чужих классов, что является важным критерием при классификации гиперспектральных изображений.

Для этапа распознавания [4] необходимо выбрать минимальный порог по показателю сопряженности. Для этого рассчитываем показатели сопряженности для найденной опорной плоскости \mathbf{Y}_k

$$\mathbf{R}_Y(m) = \frac{\mathbf{x}_m^T \mathbf{Q}_Y \mathbf{x}_m}{\mathbf{x}_m^T \mathbf{x}_m},$$

где $\mathbf{Q}_Y = \mathbf{Y}_k [\mathbf{Y}_k^T \mathbf{Y}_k]^{-1} \mathbf{Y}_k^T$, \mathbf{x}_m – вектор m из класса k , $m = 1, \dots, N_k$, где N_k – количество гипервекторов в классе k . Получаем N_k значений \mathbf{R}_Y . Полученные значения сортируем по возрастанию. Затем среди \mathbf{R}_Y берем либо минимальное значение показателя сопряженности, с учетом степени сходства выбранного класса с другими классами гиперспектрального изображения, либо выбираем порог с некоторым запасом, определяемым заданным процентом наименьших значений.

Результаты эксперимента

Алгоритм проверялся на тестовом изображении Salinas, предлагаемого в открытом пакете анализа гиперспектральных изображений MultiSpec. Это изображение было получено в рамках программы AVIRIS (AirborneVisible/ InfraredImagingSpectrometer). Размер изображения 512×217 гиперпикселей. Каждому гиперпикслю соответствует 224 спектральных полосы. Образец слоя этого гиперспектратора и тестовое изображение, разбитое на классы, показаны на рисунках 1а, 1б соответственно.

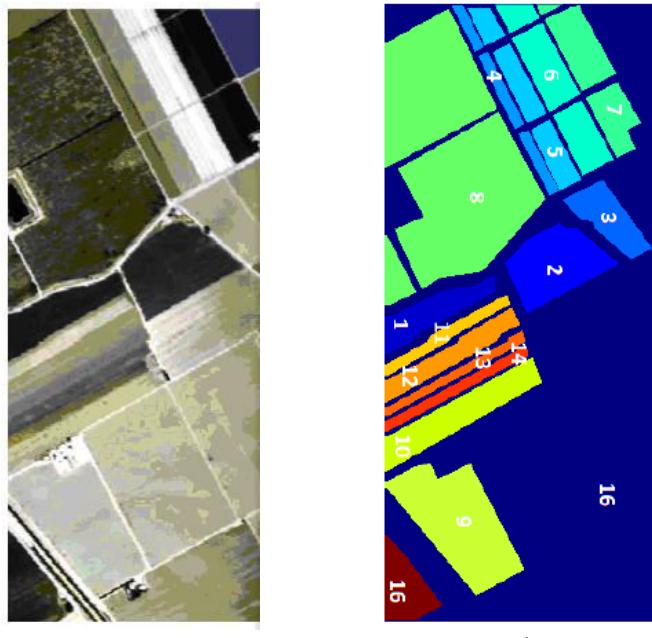


Рисунок 1 – Тестовое изображение Salinas:
 а) изображение слоя гиперспектратора с использованием искусственной расцветки;
 б) изображение, разбитое на классы

Алгоритм применялся к распознаванию четвертого, пятого и одиннадцатого классов (территория с грубовспаханными полями, гладкая поверхность земли, четырехнедельные листья салата соответственно). На рисунке показано выделение пятого и одиннадцатого классов с отсечением 20% наименьших показателей сопряженности. Из рисунка видно, что помимо своего класса распознаются еще и гиперпиксели из других классов, однако их немного.



Рисунок 2 – Выделение 5 и 11 классов соответственно

На рисунках 3а, 3б приведен пример с выделением четвертого класса с выбором различного минимального порога по показателю сопряженности. Из рисунков видно, что от выбора минимального порога сильно зависит количество ошибок распознавания не своего класса. При выборе большего минимального порога повышается качества распознавания своего класса.

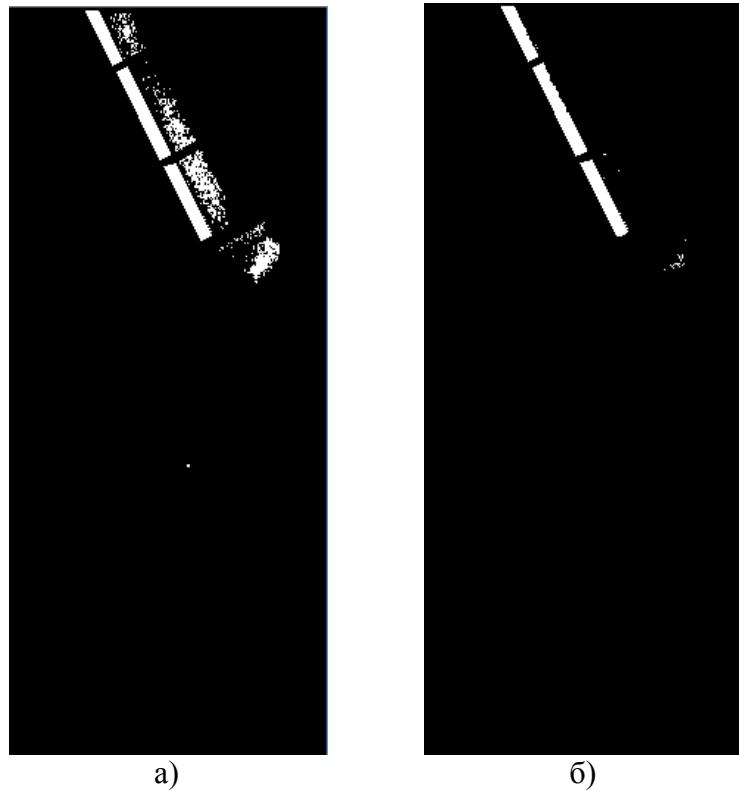


Рисунок 3 – Выделение четвертого класса:
а) с выбором минимального порога в 0%;
б) с выбором минимального порога в 2%

Заключение

Выбор подходящей опорной плоскости в приведенном алгоритме имеет достаточно высокую вычислительную сложность. Качество распознавания зависит от выбора минимального порога по показателю сопряженности. При выборе малой величины порога возрастает число ошибок, связанных с распознавания «не своих» гиперпикселей. Если увеличивать порог, то теряется часть точек из распознаваемого класса.

Литература

1. Шовенгердт, Р.А. Дистанционное зондирование. Модели и методы обработки изображений / Р.А. Шовенгердт. – М.: Техносфера, 2010. – 560 с. – ISBN 978-5-94836-244-
2. Жердев Д.А., Казанский Н.Л., Фурсов В.А. Распознавание объектов по диаграммам рассеяния электромагнитного излучения на основе метода опорных подпространств // Компьютерная оптика. – 2014. – № 38. – С. 503-510. ISSN 0134-2452.
3. Fursov, V.A. Training in Pattern Recognition from a Small Number / Vladimir A. Fursov // Proc. 15th International Conference on Pattern recognition (ISPR) 2000, Barcelona, Spain. – 2000. – Vol. 2. – P. 119-121.
4. Фурсов В.А., Бибиков С.А., Байда О.А. Тематическая классификация гиперспектральных изображений по показателю сопряженности // Компьютерная оптика. 2014. Т. 38. № 1. С. 154-157.