

Технология автоматизированного интеллектуального отбора информативных признаков для задачи классификации областей натуральных гиперспектральных изображений

М.И. Хотилин

Самарский национальный
исследовательский университет им.
академика С.П. Королева
Самара, Россия
khotilin.mi@ssau.ru

Аннотация—В данной статье описывается процесс создания автоматизированной технология отбора информативных признаков гиперспектрального изображения для осуществления процесса классификации. Описаны методы и алгоритмы поиска признаков принадлежности к определенным классам, их применения. Указаны дальнейшие пути и перспективы развития технологии и ее реализации.

Ключевые слова— гиперспектральные изображения, дискриминантный анализ, метод опорных векторов, нейронные сети, классификация, отбор признаков, Python, снижение размерности, информативные признаки

1. ВВЕДЕНИЕ

Гиперспектральные изображения представляю собой трёхмерный массив данных, включающий в себя пространственную информацию об объекте, дополненную спектральной информацией по каждой пространственной координате [1]. Анализ гиперспектральных изображений и их областей является одной из популярных тематик в области обработки изображений и компьютерного зрения. Автоматизация процесса анализа, и процесса поиска информативных признаков гиперспектральных изображений является актуальной задачей в настоящее время. В рамках данной работы рассматривается процесс построения технологии, использующей метод поиска информативных признаков и сверточные нейронные сети, для задачи классификации гиперспектральных изображений.

2. ПОСТАНОВКА ЗАДАЧИ

Выполнение обработки RGB изображений классическими методами, их классификация занимает сравнительно небольшое время и может выполняться практически на любом устройстве, в том числе и носимом. Ввиду ряда особенностей, обработка гиперспектральных изображений, будет требовать значительных вычислительных ресурсов. Например, для классификации одной области гиперспектрального изображения размером 10×10 пикселей, количество необходимых совокупных яркостных и текстурных признаков может составлять десятки тысяч.

Актуальность данной работы заключается в создании технологии, основанной на методе поиска информативных признаков изображения, а также использовании нейронных сетей, позволяющей автоматизировать процесс поиска и значительно снизить

временные и аппаратные ресурсы, используемые в процессе анализа гиперспектральных изображений.

Весь процесс данной работы можно разделить на последовательно выполняемые этапы. На первом этапе выбирается набор рассматриваемых изображений. Далее посредством использования модуля предобработки происходит отображение каждого из рассматриваемых изображений на набор значений своих текстурных и яркостных признаков.

Следующим этапом необходимо провести обработку полученного массива данных с целью снижения его размерности, поскольку данные, которые он содержит, являются значительными по объему и могут содержать значения, которые не несут значимой информации, важной при классификации. В связи с этим, необходимо произвести сокращение размерности и поиск признаков, являющихся информативными. Также можно убрать из рассмотрения константные признаки и признаки не имеющие значения для отдельных изображений.

Далее, используя метод снижения размерности, описанный автором ранее в [5], основывающийся на совместном использовании пороговой фильтрации, линейного дискриминантного анализа, произведем дальнейшее снижение размерности. Добавляя метку класса к каждому из экземпляров отображения, получаем набор для проведения дальнейшей классификации. После этого переходим к поиску информативных признаков, посредством применения метода последовательного добавления признаков.

Используя полученные на предыдущих шагах данные и информативные признаки, можно произвести обучение сверточной нейронной сети, позволяющей по набору входных параметров, например изображения и количества признаков, в качестве вывода предоставлять необходимое количество искомым информативных признаков.

3. ПРАКТИЧЕСКОЕ ИССЛЕДОВАНИЕ И ПРОГРАММНАЯ РЕАЛИЗАЦИЯ

В качестве исходных данных рассматривался набор изображений HSI Dataset v1.3, состоящий из изображений листьев растений различных классов. Размер каждого из изображений 512×512 пикселей с количеством спектральных каналов 237. Было выбрано 4 класса для рассмотрения: листья яблони, картофеля, травы, клубники. Для исследования описанного выше алгоритма, посредством Python был реализован модуль

предобработки. Данный модуль позволяет исследовать изображение, найти ряд его признаков, таких как текстурные, гистограммные, морфологические и ряд других. Общее количество признаков для каждого изображения составило 62152539.

Далее было проведено 4 серии экспериментов с различными наборами данных и классификаторами. В качестве исходных данных рассматривались:

- исходный полный набор признаков;
- фильтрованный набор, из которого были удалены «выбросы» - изображений, которые ни один из классификаторов не смог верно классифицировать;
- признаки, отобранные посредством корреляционного анализа;
- «трансформированные» признаки – первоначальный набор признаков, трансформированный посредством применения метода главных компонент.

Каждая новая серия экспериментов позволяла значительно улучшать результаты классификации. Например, при использовании корреляционного анализа, при удалении константных, N/A признаков, и варьировании коэффициента пороговой корреляции удалось значительно снизить размерность рассматриваемых данных. Рассматривались пороговые коэффициенты корреляции от 0.5 до 0.99 с шагом в 0.01. При этом количество признаков составило от 28 (при коэффициенте в 0.5) до 2364 (при 0.99).

В качестве вспомогательных использовались алгоритмы классификации: линейный дискриминантный анализ, метод опорных векторов, логистическая регрессия, метод случайного леса, а также многослойный перцептрон (MLPClassifier) с различными решающими функциями, ядрами и алгоритмами оптимизации. Результаты классификации с помощью разных алгоритмов представлены на рисунке 1.




Рис. 1. Зависимость точности классификации рассматриваемых алгоритмов от размера выборки (порогового коэффициента корреляции)

В качестве наиболее эффективного, по точности классификации и затраченным ресурсам, был выбран LDA (линейный дискриминантный анализ).

Следующим шагом является поиск информативных признаков из набора, оставшегося в результате снижения размерности. Для этого использовался метод, описанный

ранее автором в [5]. В итоге получаем паттерн обработки гиперспектральных изображений, обладающий меньшими ресурсными требованиями, по сравнению с классическими методами.

Увеличивая объем выборки, и обучая на полученных данных сверточную нейронную сеть, получаем технологию автоматизированного интеллектуального отбора информативных признаков для гиперспектрального изображения, поданного на вход данной сети. В качестве нейронной сети была выбрана сверточная CFR-сеть, использующая алгоритм минимизации контрфактических сожалений Монте-Карло (MCCFR). В настоящее время ведется работа над обучением и тонкой настройкой нейронной сети, позволяющей выполнять описанные в статье вычисления.

4. ЗАКЛЮЧЕНИЕ

Поиск признаков, определяющих однозначно принадлежность изображений к классу, является одной из значимых задач обработки изображений. В случае рассмотрения гиперспектральных изображений существующие методы обработки, определения признаков изображений и алгоритмы классификации являются ресурсозатратными и, для оперативного решения, требуется оптимизация используемых ресурсов.

Использование сверточных нейронных сетей позволит в значительной степени сократить требуемые для вычислений аппаратные и программные ресурсы, что потенциально позволяет использовать описанные в статье алгоритм и общую технологию на ряде устройств, в том числе и на носимых мобильных устройствах и беспилотных летательных аппаратах.

ЛИТЕРАТУРА

- [1] Zimichev, E.A Spectral-spatial classification with k-means++ participational clustering / E.A. Zimichev, N.L. Kazanskiy, P.G. Serafimovich // Computer Optics. – 2014. – Vol. 38. – № 2. – P. 281-286. DOI: 10.18287/0134-2452-2014-38-2-281-286
- [2] Kazanskiy, N.L. Simulation of hyperspectrometer on spectral linear variable filters / N.L. Kazanskiy, S.I. Kharitonov, S.N. Khonina, S.G. Volotovskiy, Yu.S. Strelkov // Computer Optics. – 2014. – Vol. 38.(2). – P. 256-270. DOI: :10.18287/0134-2452-2014-38-2-256-270
- [3] Khotilin, M. Classification of objects of natural hyperspectral images / M. Khotilin, N. Kravtsova, I. Rytsarev, A. Kupriyanov // 2020 International Conference on Information Technology and Nanotechnology (ITNT). – 2020. - P. 1-3. DOI: 10.1109/ITNT49337.2020.9253254.
- [4] Goncharova, E.F. Greedy algorithms of feature selection for multiclass image classification / E.F. Goncharova, A.V. Gaidel // CEUR Workshop Proceedings (IPERS-ITNT 2018 - Proceedings of the International Conference on Information Technology and Nanotechnology - Session: Image Processing and Earth Remote Sensing). – 2018. - Vol. 2210. - P. 38-46. DOI: 10.18287/1613-0073-2018-2210-38-46
- [5] Khotilin M. The technology of constructing an informative feature of a natural hyperspectral image area for the classification problem / M. Khotilin // 2021 International Conference on Information Technology and Nanotechnology (ITNT). – 2021. - P. 1-4. DOI: 10.1109/ITNT52450.2021.9649178.
- [6] Khotilin M. The technology of informative features searching method applied for the problem of classifying areas of natural hyperspectral images/ M. Khotilin // 2022 International Conference on Information Technology and Nanotechnology (ITNT). – 2022. DOI: 10.1109/ITNT55410.2022.9848638