

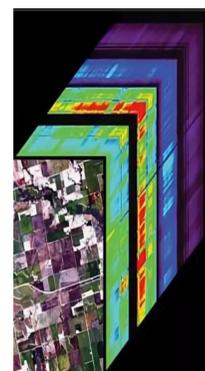
Технология автоматизированного интеллектуального отбора информативных признаков для задачи классификации областей натуральных гиперспектральных изображений

М.И. Хотилин

khotilin.mi@ssau.ru

Введение

Гиперспектральные изображения представляют собой трёхмерный массив данных, включающий в себя пространственную информацию об объекте, дополненную спектральной информацией по каждой пространственной координате. 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.



Постановка задачи

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.

Для решения данных проблем было принято решение о 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 и 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 и поиска информативных признаков. Осуществим данный процесс посредством использования метода снижения размерности, основывающимся на совместном использовании пороговой фильтрации, линейного дискриминантного анализа. 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 искоемых информативных признаков.

Рисунок 1 - Пример гиперспектрального изображения

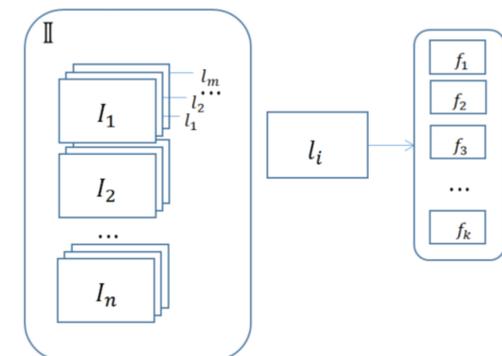


Рисунок 2 – Общий вид набора исходных данных и отображения «слой-признаки»

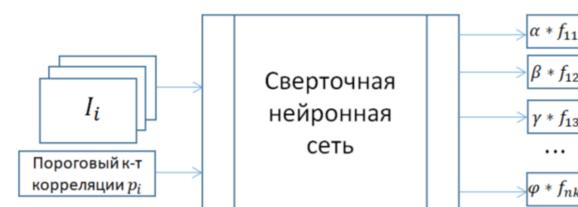


Рисунок 3 – Общий вид результирующего алгоритма

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. 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.. 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.

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.

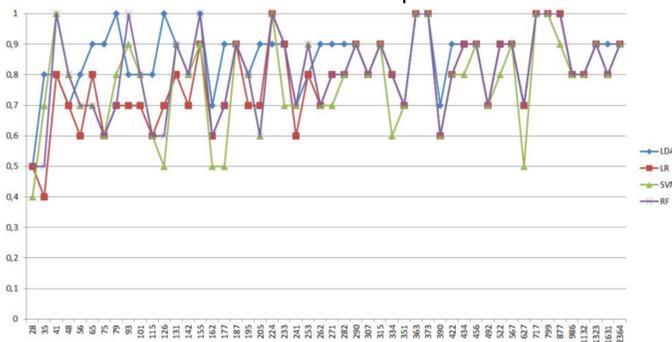


Рисунок 4 – Зависимость точности классификации рассматриваемых алгоритмов от размера выборки (порогового коэффициента корреляции)