

КОМБИНИРОВАННЫЙ ПОДХОД АВТОМАТИЗИРОВАННОГО ПОИСКА КОАССОЦИАТИВНЫХ ЗАВИСИМОСТЕЙ В КАЧЕСТВЕ ЭТАПА ПРЕДПРОЦЕССИНГА РАЗВЕДОЧНОГО АНАЛИЗА МНОГОСПЕКТРАЛЬНЫХ ИЗОБРАЖЕНИЙ

Вакуленко Дарья Витальевна¹, Кравец Алла Григорьевна²

¹Аспирант;

Волгоградский государственный технический университет;
400005, г. Волгоград, пр. им. Ленина, 28;
e-mail: dsvklnk@gmail.com.

²Доктор технических наук, профессор кафедры САПРиПК;

Волгоградский государственный технический университет;
400005, г. Волгоград, пр. им. Ленина, 28;
e-mail: agk@gde.ru.

В статье предложена комбинация подходов кластерного анализа и методов машинного обучения в области анализа космических снимков земельных наделов. Подход предполагает облегчение задачи нейронной сети в обнаружении пикселей разных классов с аналогичными сигнатурами и их правильной интерпретации. Приводится теоретическое обоснование подхода при анализе многоспектральных изображений пахотных земель. Процедура первичной работы с данными сводится к приведению данных в формат, формирующий качественное обучающее множество, от чего, в конечном итоге, будет зависеть масштабируемость и робастность модели после обучения. Для этого в работе приведена процедура предпроцессинга данных, использование которой позволит повысить точность раскрытия структурных зависимостей и их наследования на свежие данные.

Ключевые слова: подходы кластерного анализа, признаки цветовой близости объектов, коассоциативная матрица мер разнообразия, обучающее множество по сходству в признаковом пространстве, ядро свертки нейросети, трансдуктивное обучение, автоматизированная разметка.

Для цитирования:

Вакуленко, Д. В. Комбинированный подход автоматизированного поиска коассоциативных зависимостей в качестве этапа предпроцессинга разведочного анализа многоспектральных изображений / Д. В. Вакуленко, А. Г. Кравец // Системный анализ в науке и образовании: сетевое научное издание. – 2020. – № 4. – С. 20–24. – URL : <http://sanse.ru/download/411>. – DOI : 10.37005/2071-9612-2020-4-20-24.

COMBINED AUTOMATED SEARCHING FOR COASSOCIATIVE RELATIONS AS A PREPROCESSING STEP IN EXPLORATORY MULTISPECTRAL DATA ANALYSIS

Vakulenko Darya¹, Kravets Alla²

¹Post-graduate student;

Volgograd State Technical University;
400005, Volgograd, 28 Lenin Ave.;
e-mail: dsvklnk@gmail.com.

²Doctor of technical science, professor of CAD department;

Volgograd State Technical University;
400005, Volgograd, 28 Lenin Ave.;
e-mail: agk@gde.ru.

In current research a combination of several techniques – group of cluster analysis approaches and machine learning methods have been used to investigate the satellite multispectral imagery of cropland. The primary work with data makes emphasis on clustering by a group of algorithms. The method proves to make the neural network detecting of pixels with similar signatures in much more accurate way and allows to

interpret crop growth processes correctly. The technique appears useful in order to form a representative training set for powerful neural image classification model to provide the accuracy of revealing structural dependencies and carrying them over on new data. The theoretical part of research is given to plan further experimental research work.

Keywords: cluster analysis approaches, color objects similarity, zones' variety co-associative matrix, training set by similarity in feature space, convolution kernel of a neural network, transductive learning, automated marking.

For citation:

Vakulenko D., Kravets A. Combined automated searching for coassociative relations as a preprocessing step in exploratory multispectral data analysis. System Analysis in Science and Education, 2020;(4):20–24(In Russ). Available from: <http://sanse.ru/download/411>. DOI: 10.37005/2071-9612-2020-4-20-24.

Введение

На сегодняшний день в ряде сфер глубокое обучение доминирует как инструмент для решения сложных проблем, в том числе геопространственных. Современные многоспектральные системы аэрокосмического зондирования позволяют получать изображения обследуемых территорий в спектральных каналах, полностью покрывающих некоторый выбранный диапазон. Обработка такого рода изображений направлена на решение сложных задач мониторинга. Происходит рассмотрение совокупности пикселей на предмет выявления аномалий, существенных различий пикселей друг от друга. Особенности решения связаны с рассмотрением стрессового состояния растительности, принимая во внимание, что значительная часть исследований разных видов растительности традиционно сосредоточена в видимой и ближней инфракрасной области. При обработке спектральных измерений возникают сложности с линейно неразделимыми данными [3, 8]. При этом задание обучающей информации о классах – достаточно трудоемкая операция, требующая развития способов автоматизированной разметки.

Модели, построенные с использованием машинного обучения, позволяют учесть большее число зависимых величин, что и определяет высокую точность их работы [7]. Нейронные сети являются эффективным инструментом для работы с данными спутниковых приборов с задачей классификации объектов с достаточно близкими спектральными характеристиками.

1. Этап коллективного решения в кластерном анализе

Повышение качества работы современных моделей, основанных на нейронных сетях и работающих с изображениями, требует значительного количества размеченных вручную датасетов, применение сгруппированных решений в кластерном анализе может помочь в создании автоматизированной разметки для обучающих выборок. Основной информацией для распознавания объектов по многоспектральным снимкам являются измеренные спектральные яркости объектов, записанные как яркости элементов изображения [3].

При заданных сигнатурах $f_1 \dots f_m$ вектор $x = (f_1(x), \dots, f_m(x))$ будем считать признаковым описанием объекта $x \in X$. Необходимо отождествить объект и его признаковое описание. В процессе обучения на вход поступает выборка $X_N = (x_1, \dots, x_N)$, которая состоит из $X_c = (x_1, \dots, x_k)$ – размеченных объектов с заданными классами, которым они принадлежат – $Y_c = (y_1, \dots, y_k)$ и $X_u = (x_{k+1}, \dots, x_N)$ – неразмеченных объектов.

В результате обработки этих измерений требуется выполнить классификацию объектов и определить их качественные характеристики. Возникает задача с поэтапным ходом решения.

На первом шаге итеративно сгруппируем признаки с помощью ансамбля алгоритмов кластеризации, а далее необходимо последовательно использовать метки псевдоклассов, полученных при кластеризации для обучения параметров нейронной сети. Максимизация степени согласованности решений задачи разбиения выборки на непересекающиеся множества достижима с использованием коассоциативной матрицы усредненного попарного сходства A , полученной

синтезом решений ансамбля алгоритмов $\beta_1 \dots \beta_m$. Разбиение всех поданных на вход объектов X коллективом различных алгоритмов кластерного анализа даст S_m вариантов разбиения, $m = 1 \dots M$.

По результатам составляется матрица усредненного попарного сходства объектов:

$$a(i, j) = \sum_{m=1}^M \alpha_m \frac{1}{S_m} \sum_{s=1}^{S_m} h_{s_m}(i, j), \text{ где} \quad (1)$$

$i, j \in \{1, \dots, N\}$ – номера объектов ($i \neq j$)

$\alpha_m \geq 0$ – заданные веса, такие, что $\sum_{m=1}^M \alpha_m = 1$, $h_{s_m}(i, j) = 0$, если пара $(i \neq j)$ принадлежит разным кластерам в s -ом варианте разбиения, полученного алгоритмом β_m и 1, если принадлежит одному кластеру.

Элементы матрицы представляют собой средневзвешенную частоту отнесения пар объектов к одинаковым кластерам, определяются индексы качества, веса зависят от мер разнообразия вариантов. Таким образом, матрица задает меры схожести объектов в признаковом пространстве с помощью некоторых неявных преобразований.

2. Этап трансдуктивного обучения

Нейронные сети являются эффективным инструментом для работы с данными спутниковых приборов в виде изображений [5, 6, 8, 9]. Нейронной сети необходимо выстроить визуальную иерархию входного образа. Матрица входных сигналов выступает рецептивным полем, которое подвергается свертыванию. В процессе погружения рецептивное поле уплотняется для создания комбинаций низкоуровневых характеристик и распознавания все более сложных визуальных концепций. В процессе обучения эти визуальные иерархии уточняются, накапливаются и сохраняются в параметрах ядра. В случае рассмотрения моделей свертки графический материал проходит трехступенчатую процедуру распознавания: сверточный слой, слой объединения, полносвязный слой. Матрица, полученная на предыдущей итерации, может быть добавлена в качестве ядра свертки, нацеленной на выявление абстрактных понятий высокого уровня для построения визуальной иерархии в виде последовательных карт признаков.

Ход операции предполагает разбиение входных данных на фрагменты. Ядро перемещается вдоль матрицы входных данных, комбинируя пиксели ограниченного участка входной матрицы, и формирует на выходе матрицу, каждый элемент которой соответствует некоторому фрагменту исходных данных. Размер маски допускает плавающий размер. Каждая карта признаков обходится маской выбранного размера, и изображение фильтруется для выявления определенного специфичного для данной карты признака. После свертывания применяются операция уменьшения размерности (выбор *max* или *average*) по нескольким соседним нейронам, нелинейные преобразования. В заключении полносвязный слой принимает карту из предыдущего слоя и выстраивает вектор классов.




Рис. 1. Методика обучения параметров сверточной нейронной сети по меткам псевдоклассов

Подобная нейросеть в виде программного и аппаратного воплощения может повысить точность распознавания и интерпретируемость результатов, что поможет конечным пользователям оптимизировать процессы принятия решений.

3. Обобщенный вид комбинированного подхода

Решающая функция представляет собой составное решение и опирается на этапы:

1. Предпроцессинг (Провести кластеризацию $X_c \cup X_u$ алгоритмами $\beta_1 \dots \beta_m$, получив S_m вариантов разбиения от каждого алгоритма.
2. Используя группировочное решение, рассчитать матрицу усредненного попарного сходства A согласно формуле (1).
3. Провести трансдуктивное обучение нейронной сети на размеченных данных X_c , используя матрицу A в качестве ядра.
4. Создать модель связи между измеренными яркостями и признаками, уловить закономерности и масштабировать их на неразмеченные данные X_u .

Заключение

Приведенный подход может послужить в дальнейших исследованиях в задачах подготовки предтренированных моделей нейронных сетей и проведения экспертизы различного инструментария для сравнения качества классификации выделения контуров площадных элементов на коллекции космоснимков. Теоретические концепты, показанные в статье, не являются исчерпывающими, сообщество исследователей постоянно стремится улучшить точность и производительность алгоритмов. И это весомая причина для продолжения исследования.

Список литературы

1. Балов, Б. Глубокое обучение: визуальные иерархии, рецептивное поле и многое другое, что заставляет сверточные нейронные сети работать так хорошо. – URL : <https://medium.com/@balovbohdan/глубокое-обучение-разбираемся-со-свертками-6e47bfc27792> (дата обращения: 14.10.2020).
2. Бондур, В. Г. Современные подходы к обработке больших потоков гиперспектральной и многоспектральной аэрокосмической информации // Исследование Земли из космоса. – 2014. – №1. – С. 4–16.
3. Вакуленко, Д. В. Мониторинг состояния сельскохозяйственных земель на основе суперпиксельной сегментации цифровых изображений / Д. В. Вакуленко, А. Г. Кравец // Перспективные информационные технологии (ПИТ 2020) = Advanced Information Technologies and Scientific Computing (PIT 2020) : тр. междунар. науч.-техн. конф. (г. Самара, 21–22 апреля 2020 г.) / под ред. С. А. Прохорова ; Самарский национальный исследовательский ун-т им. акад. С. П. Королева, Самарский научный центр РАН. – Самара, 2020. – С. 14–21.
4. Построение устойчивых признаков детекции и классификации объектов, не обладающих характерными яркостными контрастами / С. А. Гладилин, А. А. Котов, Д. П. Николаев, С. А. Усилин // Информационные технологии и вычислительные системы. – 2014. – С. 53–60.
5. Кузнецов, А. С. Кластеризация изображений при использовании предобученных нейронных сетей / А. С. Кузнецов, Е. Ю. Семенов, Л. Д. Матросова. // International Journal of Open Information Technologies, 2019. – Vol. 7. – № 7.

6. Кустикова, В. Образовательный курс по вопросам построения и анализа качества работы глубоких нейронных сетей «Введение в глубокое обучение с использованием Intel neon Framework» // Нижегородский государственный университет им. Н.И. Лобачевского. – URL : <http://hpceducation.unn.ru/ru/обучение/курсы/intel–neon–framework>.
7. Нейронные сети: распознавание образов и изображений с помощью ИИ // Центр 2М: Разработка платформенных решений в области промышленного Интернета вещей. – URL : <https://center2m.ru/ai–recognition>.
8. Нейросеть для классификации спутниковых снимков с помощью Tensorflow на Python. – URL : <https://habr.com/ru/company/jetinfosystems/blog/468973/> (дата обращения: 25.09.2020).
9. Прикладные решения нейросетевых методов анализа данных. Знакомство с возможностями пакета фирмы StatSoft. – URL : <http://statsoft.ru/home/textbook/modules/stneunet.html> (дата обращения: 18.10.2020).