

Применение нейросетевых алгоритмов для решения задачи семантической сегментации гиперспектральных данных

А.В. Мухин
Самарский национальный
исследовательский университет им.
академика С.П. Королева
Самара, Россия
artemmukhinssau@gmail.com

Д.Н. Грибанов
Самарский национальный
исследовательский университет им.
академика С.П. Королева
Самара, Россия
cool.danik01@yandex.ru

Р.А. Парингер
Самарский национальный
исследовательский университет им.
академика С.П. Королева
Институт систем обработки
изображений - филиал ФНИЦ
«Кристаллография и фотоника»
РАН
Самара, Россия
rusparinger@gmail.com

Аннотация—Использование гиперспектральных данных позволяет решать сложные задачи анализа, которые невозможно решить, используя RGB изображения. Гиперспектральные данные часто используются в такой области человеческой жизнедеятельности как сельское хозяйство и агрокультура для наблюдения за растительностью: их степенью влажности и общего здоровья. Успешному применению нейросетевых алгоритмов для анализа гиперспектральных данных препятствует: большая размерность данных, небольшие объемы размеченных данных, влияние условий съемки на качество данных, различие в параметрах и настройках гиперспектральных камер. В данной работе рассматриваются различные подходы к применению нейронных сетей, позволяющих решать задачу семантической сегментации гиперспектральных данных учитывая их специфику. Предложенная в работе архитектура нейронной сети и метод предобработки данных позволил обучить нейронную сеть, превосходящую классические алгоритмы машинного обучения согласно метрике F1.

Ключевые слова— свертка, нейронные сети, сверточная нейронная сеть, гиперспектральные данные.

1. ВВЕДЕНИЕ

Для решения задач анализа гиперспектральных данных обычно применяют либо классические методы машинного обучения, такие как линейные классификаторы, линейные дискриминанты, метод опорных векторов, кластеризация методом k-средних и т.д. Также, для анализа гиперспектральных данных существует отдельный класс методов, основанный на применении различных индексов. Примером такого индекса может быть нормализованный разностный вегетационный индекс NDVI [1]. Данный индекс широко применяется для анализа растений.

Несмотря на все преимущества применения гиперспектральных данных – не все так однозначно. Применение к гиперспектрам классических алгоритмов не всегда позволяет достичь желаемой точности в силу ряда причин: гиперспектральные данные чувствительны к условиям съемки (ветру, освещению); существующие размеченные гиперспектральные наборы данных малочисленны и содержат в себе лишь несколько гиперспектров. Более того, гиперспектральные данные

содержат колоссальное число информации и не все алгоритмы способны обобщать такие данные. Специфичные для гиперспектров индексы также не могут решить все задачи, т.к. для каждой задачи необходим свой индекс [2], нахождение которого нетривиальная задача.

В настоящей работе рассмотрены нейросетевые алгоритмы, как наиболее точные алгоритмы интеллектуального анализа, обладающие высокой способностью к обобщению данных [3].

2. РЕЗУЛЬТАТЫ

В данной работе проведено комплексное исследование влияния архитектур нейронных сетей, методов предобработки данных и конфигурации нейронных сетей на результат семантической сегментации нейронной сети. Модели обучались на наборе из 365 гиперспектров размера 512x512 состоящих из 236 слоев размеченных на 16 классов: яблоня(I), свекла(II), капуста(III), морковь(IV), кукуруза(V), огурец(VI), баклажан(VII), трава(VIII), молочай(IX), овес(X), перец(XI), картофель(XII), щирлица(XIII) (амарант), клубника (XIV), соя (XV) и помидор(XVI).

В эксперименте использовались:

- Нейронная сеть архитектуры Unet [4].
- Нейронная сеть собственной архитектуры (Ours). Данная архитектура была вдохновлена статьёй об архитектуре L2Net [5] и в отличие от Unet имеет существенно меньше обучаемых весов.
- Алгоритм линейной регрессии (LR).
- Случайный лес (RFC).
- Квадратичный дискриминантный анализ (QDA).

Нейронные сети обучались разными способами:

- 1) Обучение нейронной на оригинальных гиперспектрах (Full).
- 2) Обучение нейронной сети на данных, обработанных методом PCA с числом главных компонент равным 17 (PCA).
- 3) Обучение нейронной сети на RGB компонентах гиперспектра (RGB).

Таким образом было исследовано влияние алгоритма уменьшения размерности на результат обучения моделей нейронных сетей.

Исходные гиперспектральные данные были вручную разделены на тренировочную и тестовую выборку. Для обучения нейронных сетей использовалась функция ошибки FocalLoss с параметром $\gamma=5.5$. Количество эпох обучения нейронных сетей 70, используемый оптимизатор – Adam [6]. Шаг обучения контролировался с помощью метода Cosine Annealing With Warm Restart [7] с изначальным значением 0.001 и параметрами $t_0=2$, $t_mult=1$. Размер батча отличался для обеих архитектур в силу ограниченности объема видеопамяти графического процессора. Также при обучении использовалась аугментация данных с помощью поворота на случайный угол и вертикальных\горизонтальных отражений. Нейронные сети были построены и обучались с помощью фреймворка Pytorch.

В таблице 1 представлена сводная таблица результатов проведенных экспериментов в терминах метрики F1.

Таблица I. РЕЗУЛЬТАТЫ ПРОВЕДЕННОГО ЭКСПЕРИМЕНТА В ТЕРМИНАХ МЕТРИКИ F1, УКАЗЫВАЮЩИЕ НА РАЗЛИЧИЯ МЕЖДУ ИССЛЕДУЕМЫМИ АЛГОРИТМАМИ И СПОСОБАМИ ПРЕДОБРАБОТКИ ДАННЫХ

Алгоритмы	Значения метрик F1	
	Среднее	Взвешенное среднее
Unet Full	0,079	0,380
Unet PCA	0,246	0,628
Unet RGB	0,141	0,520
Ours Full	0,027	0,131
Ours PCA	0,584	0,766
Ours RGB	0,083	0,334
LR	0,479	0,582
RFC	0,483	0,589
QDA	0,401	0,441

В таблице 2 представлены результаты эксперимента, где можно сравнить значения метрики F1 классических алгоритмов и “Ours PCA” для каждого класса.

3. ЗАКЛЮЧЕНИЕ

Эффективность применения нейросетевых алгоритмов для решения задач семантической сегментации гиперспектральных данных продемонстрирована в настоящей работе. В ходе проведения эксперимента было выяснено, что нейронные сети способны превзойти по точности классические алгоритмы машинного обучения согласно метрике F1.

Также в данной работе было выяснено, что ключевую роль при применении нейронных сетей играет архитектура сети. Так классическая для задач семантической сегментации архитектура Unet проигрывает в точности классическим алгоритмам. Кроме того, было выяснено, что ключевую роль в подготовке данных для обучения играет метод PCA. Без его применения нейронные сети не могли достичь результатов сопоставимых с классическими методами.

БЛАГОДАРНОСТИ

Результаты исследования были получены при поддержке государственного задания Минобрнауки России Самарскому университету в рамках работ НИЛ-602 "Фотоника для умного дома и умного города" тема 19в-Р001-602 43/21Б.

Таблица II. РЕЗУЛЬТАТЫ ПРОВЕДЕННОГО ЭКСПЕРИМЕНТА В ТЕРМИНАХ МЕТРИКИ F1 ДЛЯ КАЖДОГО КЛАССА, УКАЗЫВАЮЩИЕ НА РАЗЛИЧИЯ МЕЖДУ ИССЛЕДУЕМЫМИ АЛГОРИТМАМИ

Класс	LR	RFC	QDA	NN
Класс нормы (фон)	0,800	0,848	0,396	0,851
Яблоня	0,001	0,001	0,000	0,696
Свекла	0,787	0,709	0,890	0,937
Капуста	0,721	0,641	0,767	0,703
Морковь	0,432	0,381	0,325	0,099
Кукуруза	0,557	0,594	0,559	0,443
Огурец	0,503	0,681	0,393	0,646
Баклажан	0,393	0,280	0,135	0,212
Трава	0,374	0,289	0,130	0,836
Мочай	0,490	0,578	0,662	0,515
Овёс	0,328	0,308	0,177	0,655
Перец	0,267	0,713	0,717	0,894
Картофель	0,752	0,851	0,401	0,828
Ширица	0,860	0,690	0,805	0,907
Клубника	0,557	0,446	0,234	0,703
Соя	0,008	0,000	0,015	0,000
Помидор	0,314	0,196	0,203	0,000
Взвешенное среднее	0,582	0,589	0,441	0,766
Среднее	0,479	0,483	0,401	0,584

ЛИТЕРАТУРА

- [1] Asrar, G.Q. Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat 1 / G.Q. Asrar // Agronomy journal. – 1984. – Vol. 76(2). – P. 300-306.
- [2] Парингер, Р.А. Формирование информативного индекса для различения заданных объектов гиперспектральных данных / Р.А. Парингер, А.В. Мухин, А.В. Куприянов // Компьютерная оптика. – 2021. – Т. 45, № 6. – С. 873-878. DOI: 10.18287/2412-6179-CO-930.
- [3] Trajanovski, S. Tongue tumor detection in hyperspectral images using deep learning semantic segmentation / S. Trajanovski // IEEE Transactions on Biomedical Engineering. – 2020. – Vol. 68(4). – P. 1330-1340.
- [4] Ronneberger, O. U-net: Convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // International Conference on Medical image computing and computer-assisted intervention. – Springer, 2015. – P. 234-241.
- [5] Tian, Y. L2-net: Deep learning of discriminative patch descriptor in euclidean space / Y. Tian, B. Fan, F. Wu // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2017. – P. 661-669.
- [6] Kingma, DP. Adam: A method for stochastic optimization / D.P. Kingma, J. Ba // ArXiv, 2014.
- [7] Loshchilov, I. Sgdr: Stochastic gradient descent with warm restarts / I. Loshchilov, F. Hutter // ArXiv, 2016.