

## ПРИМЕНЕНИЕ CNN ПОСТРОЕНИЯ МОДЕЛИ ГЛУБОКОГО ОБУЧЕНИЯ В АНАЛИЗЕ ИЗОБРАЖЕНИЙ

Н. А. Жилияк

Белорусский государственный технологический университет,  
ул. Свердлова, 13а, 220006, г. Минск, Беларусь, gznadya@gmail.com

Описывается проблема работы с многомерными сейсмическими данными, а также способы оптимизации процесса обучения моделей машинного обучения на сложных данных. Предлагается алгоритм анализа и классификации контента изображений, которые позволят работать с многомерными графическими данными.

**Ключевые слова:** нейронная сеть; алгоритм; сейсмическая амплитуда; датасет; метод обучения.

Один из распространенных способов использования CNN в анализе изображений – это создание полностью новых сегментированных изображений.

Однако есть некоторые практические ограничения при работе с сейсмическими данными.

Данные часто являются трехмерными или даже 5-мерными для данных, прошедших предварительную обработку, что требует большого объема памяти на GPU. Это ограничивает максимальный размер ввода. В этом исследовании на входе выбираются подкубы сейсмических данных (амплитуд) размером  $65 \times 65 \times 65$ . Задача определяется как классификация центрального пикселя в этом районе. Для данного размера куба потребуется меньшая сеть по сравнению с тем, когда входными данными является полноразмерный seismic cube (который может быть в десятки и даже сотни раз больше представленных размеров).

Особенности данных:

- в исследовании будем использовать Volve DataSet;
- модель сети была частично вдохновлена работой Андерса У. Вальделанда, который показал, что он научился успешно классифицировать salt facies с использованием многомерных сверточных сетей;
- сеть умеет считывает стандартную 3D SGY/SEG Y. Выходной результат записывается в виде seismic куба SGY/SEG Y с тем же размеры как входной куб;
- в настоящее время реализована многомерная сверточная нейронная сеть с использованием пяти сверточных слоев, что обусловлено входной размерность данных (требует улучшений, предположительно грамотное увеличение количества слоев и использование современных CNN backbones даст лучший результат).

Обобщенная схема архитектуры CNN, использованной в этом исследовании представлена на рис. 1.

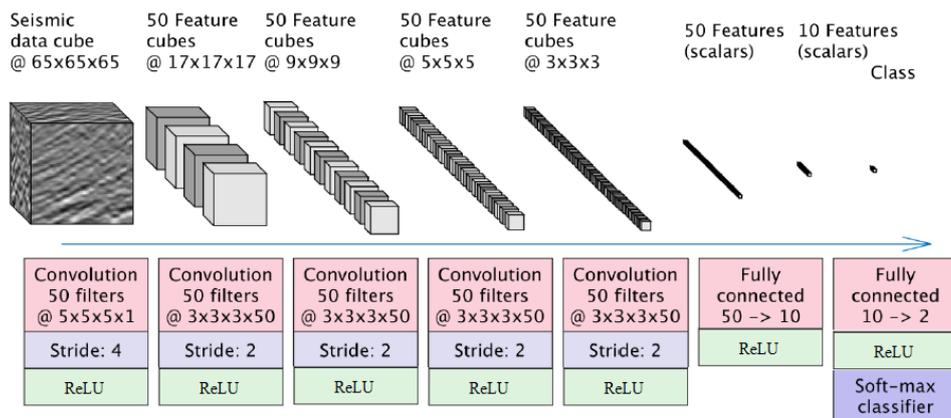


Рис. 1. Обобщенная схема архитектуры CNN

Первый сверточный слой сокращают входной куб до меньшего набора атрибутов, которые содержат релевантную информацию о структуре в этом месте. После чего последовательно извлекаем более высокоуровневые шаблоны при помощи следующих сверточных слоев. Вместо операция MaxPooling описанных выше в этой сети было принято решение использовать операции Dropout. После каждого слоя сверки используем операции Dropout(0.2), что означает прореживание. Операция Dropout похожа на MaxPooling по своему предназначению, однако она не уменьшает размерность данных, а просто отключает некоторый процент нейронов в сети, что позволяет сэкономить на памяти.

Обучение глубоких нейронных сетей с десятками слоев является сложной задачей, поскольку они могут быть чувствительны к начальным случайным весам и конфигурации алгоритма обучения.

Одна из возможных причин этой трудности заключается в том, что распределение входных данных по слоям в глубине сети может изменяться после каждого обучающего пакета данных, т.е. при обновлении весов. Это может заставить алгоритм обучения постоянно преследовать движущуюся цель.

Batch Normalization – это метод обучения очень глубоких нейронных сетей, который стандартизирует входные данные слоя для каждого мини-пакета. Это дает эффект стабилизации процесса обучения и резкого сокращения количества эпох обучения, необходимых для обучения глубоких сетей.

Добавляя операция Batch Normalization между сверточными слоями, тренировочный процесс проходит быстрее, а риск переобучения снижается.

Нелинейная функция выбрана ReLU. Несколько полносвязных слоев (обычные слои нейронной сети) добавляются в конце, чтобы предсказать класс на основе атрибутов. Некоторые части сети подбирались экспериментальным путем.

После обработки входных данных и работы алгоритма нейронной сети можно выделить ключевые слои для классификации цифрового контента, для последующей обработки их классификатором (рис. 2.).

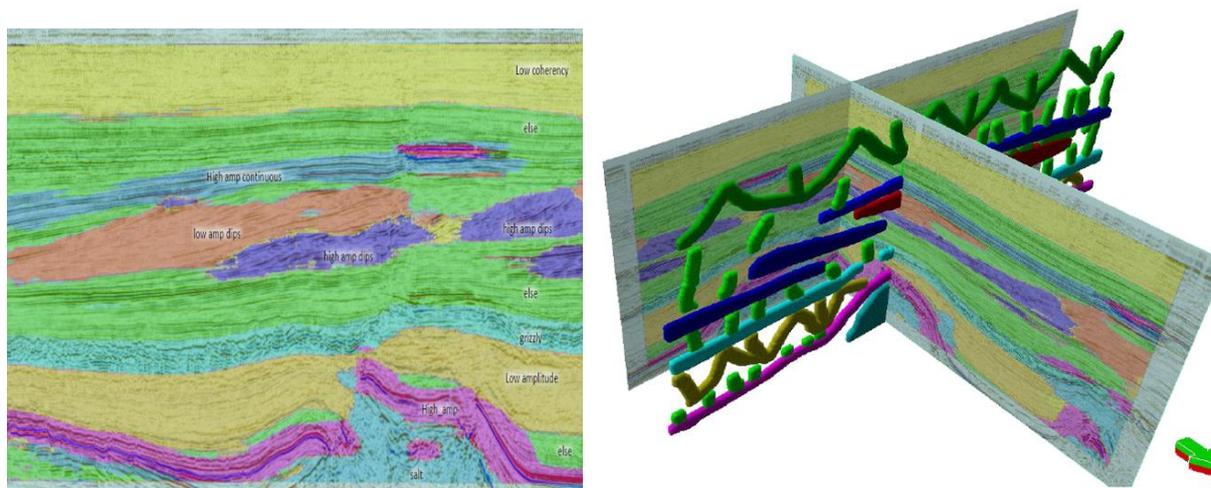


Рис. 2. Примеры работы нейронной сети

Для сравнения результатов уже существующих алгоритмов и представленного использовалась существующая модель нейросети UNET, архитектура которой изображена на рис. 3.

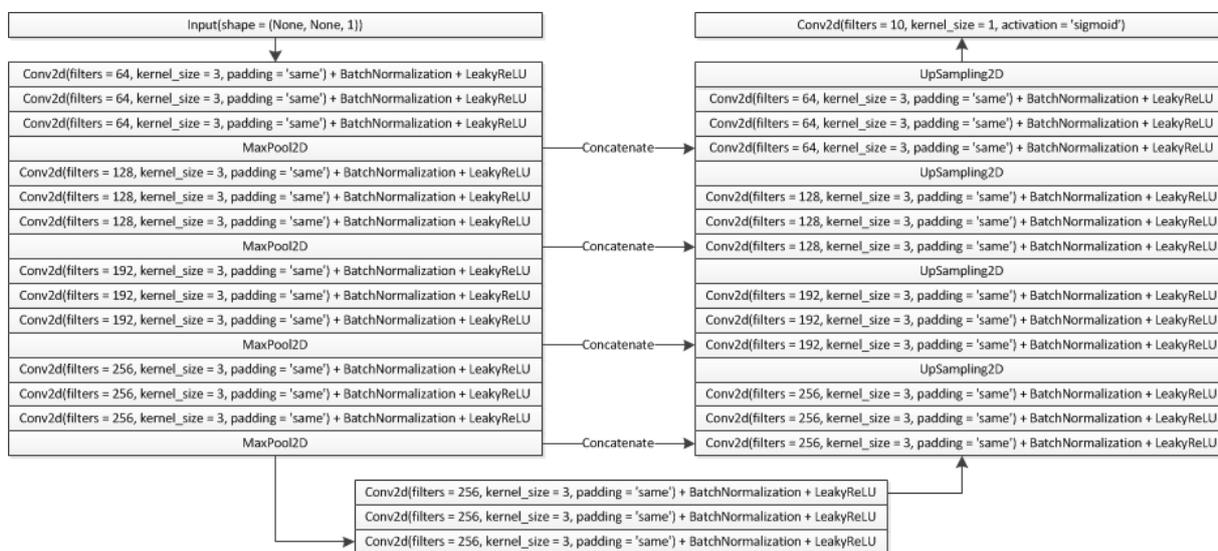


Рис 3. Архитектура нейронной сети UNET

Теперь сравним результаты с прогнозами, полученными при обучении сети UNET и разработанного алгоритма нейронной сети на малом и на большом объеме данных (рис. 4).

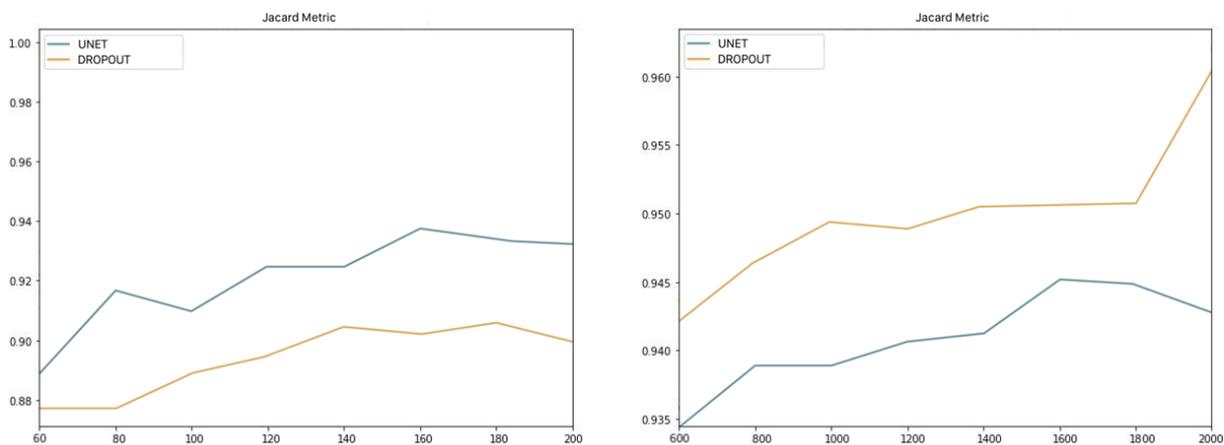


Рис. 4. Сравнение результатов сети UNET и представленной нейронной сети

Как видно из графиков на рис. 4, на малом объеме данных разработанный алгоритм нейронной сети работает хуже, это можно объяснить операцией dropout, но на больших объемах картина обстоит иначе. Так же, на больших объемах у представленной нейронной сети меньше шансов на переобучение, тем самым можно достичь более стабильной работы и лучшего выделения ключевых слоев для классификации.

В ходе исследования и работы в представленном направлении рассмотрены принципы построения глубоких нейронных сетей для обработки многомерных графических данных.

Разработан алгоритм нейронной сети для классификации цифрового контента при работе с многомерными графическими данными. Проведена оптимизация моделей глубокого обучения, что позволило существенно снизить затраты по объему GPU памяти. Таким образом получилось достичь снижение фактической стоимости процесса обучения без явных потерь в качестве.

### Библиографические ссылки

1. Громовой Н. С., Павлюкевич С Г., Усик В. Ю. Алгоритмы обеспечения безопасности клиент-серверных приложений // Научно-практический журнал «Энигма» / Раздел «Технические науки» Минск, январь 2022 г. 10 с.