

АНАЛИЗ АРХИТЕКТУР НЕЙРОННЫХ СЕТЕЙ ДЛЯ СЕГМЕНТАЦИИ ПОРОД

Денисов В.И.¹, Андренкова Е.А.²

¹ НИ ТПУ, ИШИТР, А2-39, vid3@tpu.ru

² НИ ТПУ, ИЯТШ, 0ВМ42, eaz28@tpu.ru

Аннотация

Распространение искусственного интеллекта в нефтегазовой сфере подталкивает к интенсивному применению методов машинного обучения, в особенности нейросетей, при исследовании образцов пород. В данной работе исследуются различные архитектуры нейронных сетей (U-Net, U-Net++, YOLO, Segnet) и результаты их работы на изображениях керна для выявления наиболее эффективной для данной задачи модели, а также преимуществ каждой из моделей. Результаты исследования могут применяться в дальнейшем для подбора архитектуры сети наиболее подходящей для решения задачи, связанной с сегментацией образцов пород.

Ключевые слова: изображения керна, сегментация, сверточные нейронные сети.

Введение

Современные технологии машинного обучения активно используются в нефтегазовой и геологической отраслях для автоматизации анализа изображений керна (цилиндрических образцов пород из скважин). Фотографии керна содержат ценную геологическую информацию, необходимую для изучения строения месторождений, оценки свойств пластов и прогнозирования распределения углеводородов [1-3].



Рис. 1. Пример изображения керна

Традиционные методы анализа керна трудоемки, поэтому актуально применение нейронных сетей для автоматической сегментации и классификации пород. Однако существующие подходы имеют ограничения, такие как недостаточный объем данных и высокая вычислительная сложность [4-5].

В данной работе сравниваются архитектуры нейронных сетей (U-Net, U-Net++, YOLO 8s-seg, YOLO 11s-seg, Segnet) для сегментации образцов пород с целью выявления наиболее эффективных моделей и структурных особенностей, влияющих на точность геологической сегментации.

Цель работы – исследовать результаты сегментации керна на фотографиях и выявить особенности архитектур нейронных сетей, повлиявшие на метрики (такие как IoU и Dice).

Ключевые задачи работы:

1. Сформировать датасет для проведения исследования.
2. Сравнить производительность различных архитектур и определить оптимальную для сегментации образцов пород.
3. Определить, какие структурные элементы нейросетей оказывают наибольшее влияние на эффективность работы сети при сегментации пород.

Результаты исследования позволят выработать рекомендации по выбору и оптимизации моделей для задач геологической сегментации.

Формирование датасета

В ходе работы использовались реальные фотографии керна с разрешением 4000х4000 пикселей. Поскольку не все фотографии имеют одинаковые параметры длины и ширины, на многие из них были добавлены чёрные рамки (рис. 2).




Рис. 2. Фотография керна для обучения U-Net

На основе каждой фотографии в обучающем наборе с использованием Photoshop создана бинарная маска, где чёрный цвет – отсутствие породы, белый – её наличие. С учётом того, что на одной фотографии находится в среднем 5 образцов по 1-2 метра каждый, то глубина обучающей выборки составляет около 1 км керна, и в самой выборке находится 167 фотографий. Валидационная выборка, предназначенная для сегментирования нейронной сетью, содержит примерно 200 метров керна, что составляет 20% от обучающей выборки (33 фотографии).

Результаты обучения моделей нейронных сетей

Далее будут рассмотрены архитектуры сетей для анализа. Модели были обучены на датасете, описанном выше.

U-Net

Классическая архитектура для сегментации изображений, состоящая из энкодера (сжимающего изображение) и декодера (восстанавливающего сегментированное изображение). Использует пропускные соединения для передачи признаков с энкодера в декодер [6]. Результаты обучения модели представлены в таблице 1.

Таблица 1. Результаты обучения U-Net модели

Модель	Train Dice	Train IoU	Val Dice	Val IoU	Время обучения (25 эпох)	Среднее время обработки 1 изображения	Используемая память (ГБ)
U-Net	0,9220	0,8870	0,9060	0,8540	~2 часа	~0,15 сек	~4,0 ГБ

Данная архитектура достаточно эффективна и часто применяется при решении задач, где требуется выделять большое количество признаков, например, в медицинских изображениях.

U-Net++

Модель СНС U-Net++ представляет из себя модифицированную вариацию U-Net с вложенными структурами. Отличается более плотными пропускными соединениями между слоями энкодера и декодера, что позволяет передавать признаки разных уровней абстракции и повышает точность сегментации [7].

В таблице 2 приведены результаты обучения модели на U-Net++ архитектуре.

Таблица 2. Результаты обучения U-Net++ модели

Модель	Train Dice	Train IoU	Val Dice	Val IoU	Время обучения (25 эпох)	Среднее время обработки 1 изображения	Используемая память (ГБ)
U-Net++	0,9701	0,9053	0,9205	0,8502	~3 часа	~0,18 сек	~6,8 ГБ

Как видно из таблицы 2, U-Net++ показывает более высокие показатели точности работы. Метрики Dice и IoU на тренировочном наборе для U-Net++ оказались больше на 5 % и 2% соответственно, а для валидационного набора метрика Dice оказалась больше на 1,6%, а метрика IoU меньше на 0,4%.

Исходя из архитектуры сетей можно заключить, что такое влияние оказало использование в U-Net++ модифицированного декодера с добавлением промежуточных сверточных слоев между уровнями. Это позволяет формировать более детальные карты признаков, что особенно важно для выделения сложных объектов.

Однако время обучение для U-Net++ возросло на 50%, а используемая память - на 2,8 ГБ. Эти показатели говорят о том, что не все модификации U-Net++ относительно оригинальной сети оказались успешными. В частности, можно предположить, что увеличение времени на обработку возникло из-за дополнительных сверточных блоков в skip-connections: в отличие от простых skip-connections в U-Net, U-Net++ использует сверточные слои для объединения feature maps из разных уровней, а каждый такой блок требует дополнительных вычислений. Кроме прочего, это увеличивает количество параметров, что также влияет на скорость.

YOLO 8s-seg

Эта архитектура представляет собой одностадийный детектор объектов, расширенный для решения задач сегментации. Она включает в себя backbone, neck и head. Backbone отвечает за извлечение признаков из входного изображения, neck объединяет признаки с разных уровней backbone, а head использует эти признаки для одновременного предсказания bounding box, классов объектов и масок сегментации [8]. На рис. 3 представлены метрики качества обучения:




Рис. 3. Метрики обучения YOLO 8s-seg

Из графика видно, что метрики в целом увеличиваются с количеством эпох, однако их рост сопровождается скачками, образующими локальные максимумы и минимумы. Это обусловлено тем, что данная модель в настоящее время устарела и подходит не для всех типов задач сегментации и классификации. Ниже для сравнения приведена усовершенствованная модель архитектуры YOLO.

YOLO 11s-seg

Является развитием семейства YOLO с усовершенствованными компонентами по сравнению с YOLO 8. Как и YOLO 8, это одностадийный детектор с функцией сегментации [8]. Далее, аналогично YOLO 8s-seg, на рис. 4 представлены метрики обучения YOLO 11s-seg.




Рис. 4. Метрики обучения YOLO 11s-seg

Сравнивая полученные графики, можно заметить, что для YOLO 11 все параметры метрик постепенно увеличиваются, в отличие от хаотично увеличивающихся и уменьшающихся значений метрик для YOLO 8. При этом для обоих вариантов данной архитектуры после 17-й эпохи начинается резкий рост значений всех метрик, и, следовательно, значительно растёт качество обработки изображений. Это связано с тем, что на 17-й эпохе модель находит оптимальные настройки весов благодаря снижению learning rate или накопленному опыту от сложных примеров. Однако после 20 эпохи происходит переобучение сети, из-за чего результаты становятся хуже, поэтому оптимальное количество эпох равно 20.

Результаты обучения YOLO 11s-seg и YOLO 8s-seg представлены в таблице 3.

Таблица 3. Результаты обучения YOLO 11s-seg модели

Модель	Precision, %	Recall, %	mAP, %	F1 Score, %	IoU, %
YOLO 8s-seg	0,804	0,721	0,850	0,792	0,840
YOLO 11s-seg	0,855	0,838	0,852	0,845	0,865

Важным замечанием является то, что для YOLO искусственно расширили данные за счет аугментации, так как эта архитектура требует большого объема информации: по метрикам mAP50 и mAP50-95 было выявлено, что для достижения наивысших показателей, модели требуется датасет, превышающий имеющийся в 9,6 раз. При этом, несмотря на недостаток данных, сеть показала результат IoU, близкий к U-Net - такие высокие показатели метрик были достигнуты благодаря использованию механизмов внимания. Нельзя не отметить, что модель

YOLO 11s оказалась меньше и быстрее, чем U-Net++. Вероятнее всего это связано с применением 3D свертки.

Пример сегментации с использованием обученной модели YOLO 11s-seg приведен на рис. 5. Как видно, имеется большое количество неточностей, когда модель выделяет либо часть коробки, либо недовыделяет часть керна. Это может сильно сказаться на результатах исследования керна, в связи с чем применять модель в таком виде невозможно.



Рис. 5. Пример работы сети YOLO 11s-seg

Segnet

SegNet отличается от ранее рассмотренных U-Net и YOLO следующими особенностями:

- Энкодер-декодер с сохранением индексов пулинга: в отличие от U-Net SegNet запоминает только индексы максимальных значений при пулинге, что снижает потребление памяти, но может ухудшить точность.
- Отсутствие полносвязных слоев (как в YOLO): в отличие от YOLO, которая детектирует объекты через предсказание bounding box и классов, SegNet фокусируется только на пиксельной классификации без использования якорных боксов.
- Более легкая декодерная часть по сравнению с U-Net: SegNet полагается на пересохраненные индексы пулинга.

На рис. 6 представлены значения метрик во время обучения.




Рис. 6. Метрики и валидация обучения Segnet

Судя по представленным данным, скачки не выглядят аномальными. Есть небольшие колебания (например, в 4-й эпохе Train Dice падает с 0.62 до 0.60), но в целом динамика стабильная: Train Loss равномерно уменьшается, Train Dice и Train IoU постепенно растут, несмотря на небольшие колебания, Val Loss тоже последовательно снижается, а метрики валидации (Dice, IoU) растут.

В таблице 4 приведены метрики обучения модели SegNet.

Таблица 4. Результаты обучения Segnet модели

Модель	Train loss, %	Train Dice, %	Train IoU, %	Val Loss, %	Val Dice, %	Val IoU, %
Segnet	0,22	0,86	0,84	0,20	0,84	0,82

Можно заметить, что у данной модели параметры IoU и Dice ниже, чем у U-Net и U-Net++. Это говорит о том, что в целом результаты обучения этой нейросети хуже и могут содержать ошибки при сегментации.

Заключение

Таким образом, был произведен обзор существующих архитектур сетей для решения задачи сегментации изображений пород, каждая сеть была обучена на сформированном датасете, и были получены результаты обучения. Как видно из анализа, наибольшую эффективность в совокупности по качеству сегментации и скорости работы показывает U-Net.

Среди особенностей сетей, заметно повлиявших на качество сегментации образцов пород, можно выделить:

1. Механизмы внимания YOLO 11s-seg увеличивают концентрацию сети на мелких признаках и слоистости, раздробленности пород.
 2. Промежуточные связи между слоями, использованные в U-Net++, позволили более точно определять признаки, что повысило качество сегментации.
 3. Применение 3D свертки в YOLO 11s-seg позволило сделать модель более быстрой и легкой.
- Выделенные особенности сетей можно использовать далее для модификации существующих архитектур, а также подборе сети под конкретную задачу.

Список использованных источников

1. Иванченков В.П., Кочегуров А.И., Нгуен С.Х. Фазочастотный алгоритм прослеживания сейсмических сигналов с управляемой протяженностью функции качества // Научный вестник Новосибирского государственного технического университета. – 2014. – №.4. – С. 59-68.
2. Иванченков В.П., Кочегуров А.И., Орлов О.В. Применение методов фазочастотного анализа сейсмических волн для изучения околоскважинного пространства // Нефтяное хозяйство. – 2015. – № 10. – С. 58–63.
3. Кочегуров А.И., Иванченков В.П., Орлов О. В. Прогноз геологического разреза на основе детальной обработки сейсмических материалов в программно-алгоритмическом комплексе «ГЕОСЕЙФ» // Известия томского политехнического университета. Инжиниринг георесурсов. -2019. Т. 330. №. 6. - С. 134-144.
4. Кочегуров А.И., Денисов В.И., Задорожных Е.А. Анализ применения методов машинного обучения в задачах классификации пород на образцах керна // Известия Томского политехнического университета. Инжиниринг георесурсов. –2024. – Т. 335. – № 9. – С. 148–159.
5. Денисов В.И., Задорожных Е.А. Применение средств машинного обучения для исследования образцов керна // Сборник трудов XXI Международной научно-практической конференции студентов, аспирантов и молодых ученых МСИТ-2024. – Томск: изд-во ТПУ. – 2024. – С. 155-160.
6. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // MICCAI 2015. Lecture Notes in Computer Science. – 2015.
7. Zongwei Zhou, Jianming Liang, Nima Tajbakhsh. UNet++: A Nested U-Net Architecture for Medical Image Segmentation // Conference: 4th Deep Learning in Medical Image Analysis (DLMIA) Workshop. – Spain. – 2018.
8. Ultralytics YOLO Docs // Ultralytics, 2025. – [Электронный ресурс]. – URL: docs.ultralytics.com (дата обращения: 28.03.2025).