

Сергей Михайлович ДЬЯЧКОВ¹
Ольга Анатольевна ЯДРЫШНИКОВА²
Дмитрий Валерьевич ПОЛЯКОВ³
Надежда Петровна ДЕВЯТКА⁴
Павел Игоревич ЧЕРМЯНИН⁵
Михаил Владимирович ДМИТРИЕВСКИЙ⁶

УДК 004.891

**АВТОМАТИЧЕСКОЕ ОПРЕДЕЛЕНИЕ ПОРОДЫ
ПО ФОТОГРАФИЯМ КЕРНА
СОВРЕМЕННЫМИ МЕТОДАМИ
МАШИННОГО ОБУЧЕНИЯ**

- ¹ главный специалист
отдела прототипов и развития технологий,
Тюменский нефтяной научный центр
smdyachkov@tnnc.rosneft.ru; ORCID: 0000-0002-3238-3259
- ² кандидат технических наук,
главный менеджер отдела алгоритмизации,
Тюменский нефтяной научный центр
oayadrishnikova@tnnc.rosneft.ru
- ³ специалист отдела прототипов и развития технологий,
Тюменский нефтяной научный центр
dvpolyakov3-tnk@tnnc.rosneft.ru; ORCID: 0000-0002-9726-1375
- ⁴ начальник отдела литолого-фациального
и седиментологического изучения керна,
Тюменский нефтяной научный центр
npdevyatka@tnnc.rosneft.ru
- ⁵ начальник управления развития интеллектуальных технологий,
Тюменский нефтяной научный центр
pichermyanin2@tnnc.rosneft.ru
- ⁶ кандидат физико-математических наук, главный менеджер
отдела разработки наукоемких систем,
Тюменский нефтяной научный центр
mvdmitrievskiy@tnnc.rosneft.ru

Цитирование: Дьячков С. М. Автоматическое определение породы по фотографиям кернa современными методами машинного обучения / С. М. Дьячков, О. А. Ядрышникова, Д. В. Поляков, Н. П. Девятка, П. И. Чермянин, М. В. Дмитриевский // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. 2021. Том 7. № 4 (28). С. 181-198.
DOI: 10.21684/2411-7978-2021-7-4-181-198

Аннотация

Послойное описание кернa выполняется для понимания закономерностей строения геологического разреза, прогнозирования развития коллекторов, уточнения стратиграфических границ и получения подсчетных параметров для оценки запасов углеводородного сырья. При этом название породы — один из ключевых параметров, определяемых при послойном описании.

В данной работе представлен сравнительный анализ двух подходов определения породы методами машинного обучения: на основе графических идентификаторов и сверточных нейронных сетей. Исходная выборка содержала фотографии кернa месторождений Тюменской свиты (8 месторождений, 15 скважин, более 2 км кернa) при дневном освещении. Для анализа выбраны 4 основных класса пород (алевролиты, аргиллиты, песчаники, угли). Для данных пород сформированы окна 5×5 см и нормированы до 299×299 пикселей. Общая выборка превысила 90 тыс. окон: 70% — обучающая выборка (60 359 окон) и 30% — тестовая (31 140 окон). Обучающая и тестовая выборки содержат фотографии кернa с разных месторождений.

Сравнение производилось между сверточными нейронными сетями (ResNet, ResNeXt, Inception и др.) и классификатором (типа XGBoost) на основе графических идентификаторов двух типов: цветовые (средний цвет, доминирующие цвета) и текстурные (энтропия, число Эйлера, контраст, непохожесть, однородность, энергия, корреляция). По результатам экспериментов модель на основе сверточных нейронных сетей оказалась более чувствительна к неявным признакам и позволила сократить ошибку по средневзвешенной f1-мере по отношению к ансамблю слабых классификаторов на 12,5% на тестовой выборке даже без оптимизации гиперпараметров.

Таким образом, можно сделать вывод, что модель на основе сверточных нейронных сетей более чувствительна к неявным признакам, которые сложно извлечь, используя известные графические идентификаторы. С другой стороны, подход на основе графических идентификаторов и ансамбля слабых классификаторов может быть использован без специализированных вычислительных мощностей (видеокарт).

Ключевые слова

Фотография кернa, сверточные нейронные сети, графические идентификаторы, XGBoost, компьютерное зрение, геология, название породы.

DOI: 10.21684/2411-7978-2021-7-4-181-198

Введение

Для эффективного выполнения производственных задач, связанных с добычей углеводородов, важно и необходимо знать, какими горными породами представлен разрез лицензионного участка или месторождения, его расчлененность, какими свойствами обладают отложения, его слагающие, в пределах каких глубин распространены продуктивные пласты и горизонты. Прямым источником этой информации является керновый материал из скважин. КERN — это монолитный образец горной породы, правильной (цилиндрической) формы, извлеченный из земных недр на поверхность, анализируя который возможно: установить закономерности вертикального строения геологического разреза и его литологические характеристики; уточнить стратиграфические границы и выделить маркирующие (реперные) слои; спрогнозировать распространение коллекторов и флюидоупоров и их свойства; оценить характер насыщения, геохимические показатели и подсчетные параметры для оценки запасов углеводородного сырья.

Для понимания закономерностей строения разреза в первую очередь выполняется выделение его элементарных единиц — слоев — и проводится их описание. При этом определяющими являются следующие ключевые признаки: тип породы, цвет, насыщение, структура породы (гранулометрический и минеральный состав, сортировка, цемент), текстура, биотурбация (интенсивность и разнообразие), органические остатки, вторичные изменения, пустоты, трещины, характер контактов. В итоге формируется литологическое описание разреза с детальными характеристиками каждого слоя.

На текущий момент Тюменский нефтяной научный центр имеет на хранении более 150 км керна с ежегодным приростом в 10-15 км, более 100 тыс. цифровых снимков керна с приростом 20 тыс. в год и более 1 млн выделенных слоев с приростом в 90 тыс. ежегодно.

Определение ключевых признаков и выполнение послойного описания занимает на сегодняшний день значительную часть времени высококвалифицированных специалистов-литологов, работа которых может быть оптимизирована путем автоматизации.

Обзор литературы

В научной литературе были найдены решения задачи определения пород по фотографиям керна. В таблице 1 представлены три наиболее детализированных решения от Сколковского института науки и технологий (Сколтех) совместно с коллегами из других организаций [5, 8], Schlumberger [3] и австралийского университета Нового Южного Уэльса (University of New South Wales, UNSW) [4]. Решения от научных организаций (Сколтеха и UNSW) основаны на сверточных нейронных сетях широко распространенных архитектур (AlexNet, VGG, GoogLeNet, ResNet, Inception-v3, ResNeXt). Точность для данных решений достаточно сильно различается, что может быть продиктовано исходным качеством данных (150 dpi для решения Сколтеха против 400 dpi для решения UNSW) и количеством определяемых классов (6 классов против 4), таким образом, можно утверждать, что более высокое качество изображений

Таблица 1

Аналогичные решения

Table 1

Similar solutions

Компания	Сколтех	Schlumberger	UNSW
Суммарная мощность керна	2 км	Не уточняется	~3 км (800 ящиков по 3-5 м в каждом)
Количество окон	20 000 шт.		76 500 шт.
Размер окон	10 × 10 см		2 × 2 см
Разрешение окон	606 × 606 px		240 × 240 px
Качество изображения	150 dpi		~400 dpi
Количество классов	6 классов		4 класса
Модель	AlexNet, VGG, GoogLeNet, ResNet	Фильтры для свертки, Gaussian mixture, BIC	ResNet, Inception-v3, ResNeXt, post-processing
Точность на тестовой выборке лучше модели	Precision: 72% Recall: 60% F1: 0,57	Не уточняется	Accuracy: 88,74%

и меньшее количество классов позволяют значительно повысить качество модели. Так, решение университета Нового Южного Уэльса на 15-20% точнее решения, разрабатываемого Сколтехом (таблица 1).

Материалы и методы

Подготовка исходных данных

Изображения керна для описания получают путем фотографирования кусков керна диаметром от 80 до 100 мм в одной проекции вдоль ствола при дневном и ультрафиолетовом свете (подсвечивает имеющиеся в керне следы углеводородов). КERN в момент съемки закреплен на специальном столе длиной 6 м, который можно передвигать вдоль ствола. Высота камеры, которая используется для съемки, фиксирована. Для обеспечения правильной цветопередачи оборудование, а именно фотоаппарат и освещение, калибруют вручную с использованием эталонных мишеней. Одновременно производится фотографирование участка длиной не более 1 м с приложенной к керну масштабной линейкой. Далее полученные изображения обрабатываются оператором, из них вырезается только часть, содержащая информативную область. Выделенную часть сохраняют в форматах JPG и PDF. По итогам формируется литологическое описание слоя с ключевыми признаками, в том числе с указанием породы, цвета, насыщения, зернистости и других параметров. Таким образом, можно говорить

об унифицированном и хорошо регламентированном процессе получения первичных данных. Все выше описанные данные загружаются в корпоративную систему ИС «РН-Лаб» в структурированном виде, в том числе и изображение с указанием границ слоев [1, 2].

Описание выборки

Для обучения моделей была осуществлена выгрузка фотографий и послыного описания 15 скважин с 8 месторождений Тюменской свиты из корпоративной системы ИС «РН-Лаб» [1, 2]. Было предоставлено 2 432 фотографии керн при дневном свете, что эквивалентно 2,4 км породы. Суммарное количество слоев составило 4 378. Для анализа были выбраны 4 основных породы, чаще всего встречающиеся в рамках исследуемой выборки: песчаники, алевролиты, аргиллиты, угли.

Для каждого слоя из исходного описания берутся отметки кровли и подошвы данного слоя. Далее в рамках одного слоя из изображения последовательно вдоль ствола керн нарезаются окна размером 5×5 см с фиксированным шагом смещения для каждого названия породы, вычисляемого по формуле (1). Затем для корректной работы моделей все вырезанные окна нормируются до размера 299×299 пикселей.

При формировании датасета мы столкнулись с проблемой несбалансированности данных. По этой причине было решено брать для каждой породы собственный шаг скользящего окна, зависящий от суммарной высоты породы данного класса. Стандартный шаг (*default_step*) для самой высоко представленной породы (песчаники) принят равным 2 см. Для остальных пород он рассчитывается пропорционально суммарной высоте данного класса (*sum_height_of_class*) относительно высоты самого представленного класса *sum_height_of_class*:

$$step = \mathit{math.ceil} \left(\mathit{default_step} \cdot \frac{\mathit{max_sum_height}}{\mathit{sum_height_of_class}} \right), \quad (1)$$

где *math.ceil* — операция округления значения в большую сторону; *default_step* — значение шага для наиболее представленной породы в выборке; *max_sum_height* — суммарная мощность керн наиболее представленной породы в выборке; *sum_height_of_class* — суммарная мощность керн породы, для которой рассчитывается шаг смещения окна.

Далее полученная выборка разбивается на обучающую и контрольную в соотношении 70 : 30 (таблица 2).

Описание используемых моделей

Нейронная сеть

В рамках исследования были протестированы следующие архитектуры предобученных сверточных нейронных сетей, реализованных с помощью свободно распространяемой библиотеки PyTorch [14]: SqueezeNet1.1, DenseNet121, DenseNet161, Inception-v3, NASNetLarge, PNASNet5Large, ResNet18, ResNet34, ResNet152, ResNeXt101 64×4d, ResNeXt101 32×4d, SENet154, VGG13, VGG16bn, VGG19bn.

Таблица 2

Распределение пород в исследуемой выборке

Table 2

Distribution of rocks in the sample

Порода	Количество слоев	Суммарная мощность, м	Шаг, см	Количество окон		
				Всего	Обучающая выборка	Тестовая выборка
песчаники	2 058	568,03	2	23 891	15 457	7 699
алевролиты	1 490	377,4	1,33	23 680	16 767	6 830
аргиллиты	205	53,02	0,19	22 751	15 035	7 494
угли	106	20,49	0,07	22 217	13 100	9 117

Для нивелирования эффекта переобучения были использованы следующие техники:

- аугментация: изображения с равной долей вероятности могли отразиться либо горизонтально, либо вертикально;
- добавлен dropout-слой: нейрон исключается из сети с вероятностью 30%;
- регуляризаторы L1 и L2: наложение штрафов на веса с наибольшими значениями для минимизации их L1 и L2-нормы соответственно.

Ансамбль слабых классификаторов по данным графических идентификаторов

Для реализации данного подхода были использованы две свободно распространяемые библиотеки: Scikit-Image [16] для извлечения графических идентификаторов по окнам и XGBoost для построения модели классификации [6].

В качестве графических идентификаторов использовались следующие характеристики: цветовые (средний цвет, доминирующие цвета) и текстурные (энтропия, число Эйлера, контраст, непохожесть, однородность, энергия, корреляция).

Цветовые графические идентификаторы были получены на основе исходного изображения, представленного в виде трехмерной матрицы, в которой два первых измерения представляют высоту и ширину исходного изображения, а третье измерение отвечает за цвет. Спектр исходных изображений включал всего три канала базовых цветов: красный (R), зеленый (G) и синий (B). Средний цвет рассчитывался как среднее арифметическое значение для каждого канала (базового цвета) исходного изображения (рис. 1.1). Палитра цветов рассчитывалась путем попиксельной кластеризации изображения методом K-средних [12] с заданным количеством искомым цветов. В качестве объектов кластеризации выступали точки в трехмерном пространстве базовых цветов (R, G, B). Количество искомым цветов было выставлено в соответствии с результатами, полученными в компании Schlumberger [3], а именно их увеличение до 11 дает

наибольший прирост извлекаемой информации. Результат кластеризации представлен на рис. 1.2. Далее для цветов полученной палитры производилась оценка их представленности на изображении путем вычисления процента изображения (рис. 1.2), представленного каждым из цветов полученных кластеров. Три наиболее представленных цвета на изображении назывались доминирующими и включались в анализ.

Для вычисления текстурных графических идентификаторов использовались изображения в градациях серого и черно-белые изображения (рис. 1.3-1.4). Так,




Рис. 1. Примеры изображений, использованных для вычисления графических идентификаторов (по горизонтали: А — алевролит, В — аргиллит, С — песчаник, D — уголь; по вертикали: 1 — исходные изображения, 2 — изображения после кластеризации, 3 — изображения в градациях серого, 4 — черно-белые изображения)

Fig. 1. Examples of images used to visual descriptors computing (horizontal: A — siltstone, B — mudstone, C — sandstone, D — coal; vertical: 1 — original image, 2 — image after clustering, 3 — grayscale images, 4 — black and white image)

на основе изображения в градациях серого (рис. 1.3) была рассчитана энтропия Шэннона [18], позволяющая определить имеющуюся локальную неоднородность текстуры. По черно-белому изображению (рис. 1.4) была произведена оценка топологии путем расчета числа Эйлера [11], которое позволяет оценить глобальную неоднородность текстуры изображения. Для оценки значений других графических идентификаторов, инвариантных к взаимному расположению и интенсивности, по изображениям в градациях серого (рис. 1.3) рассчитывались матрицы совместной встречаемости оттенков серого [13] для 4 соседних пикселей: контраст, непохожесть, однородность, энергия, корреляция — общепризнанных статистик Харалика [7].

Результаты

Для оценки результатов работы алгоритмов использовались стандартные метрики оценки качества классификации: precision, recall, f1-score и accuracy.

Нейронная сеть

По результатам вычислительных экспериментов наилучший результат получила модель с архитектурой ResNeXt101 32×4d [17]. Данная архитектура отличается от семейств VGG/ResNet тем, что пытается использовать больше подпространств свертки, но для соблюдения баланса сложности и производительности данные подпространства имеют меньшую размерность. Данная архитектура не раз превосходила рассмотренные нами архитектуры на модельных задачах (ImageNet1K [15], CIFAR [9], COCO [10]), что и было освещено в оригинальной статье и подтвердилось в нашей работе. Результаты классификации для обучающей и контрольной выборки представлены в таблице 3 и на рис. 2.

Таблица 3

Качество классификации модели
ResNeXt101 32×4d

Table 3

Classification quality
of the ResNeXt101 32×4d model

Характеристика	алевролиты	аргиллиты	песчаники	угли	accuracy	macro avg	weighted avg
Обучающая выборка							
precision	0,86	0,83	0,89	0,98	0,88	0,89	0,88
recall	0,79	0,93	0,87	0,94	0,88	0,89	0,88
f1-score	0,82	0,88	0,88	0,96	0,88	0,89	0,88
Контрольная выборка							
precision	0,80	0,79	0,92	0,92	0,86	0,86	0,86
recall	0,77	0,80	0,93	0,94	0,86	0,86	0,86
f1-score	0,79	0,80	0,92	0,93	0,86	0,86	0,86

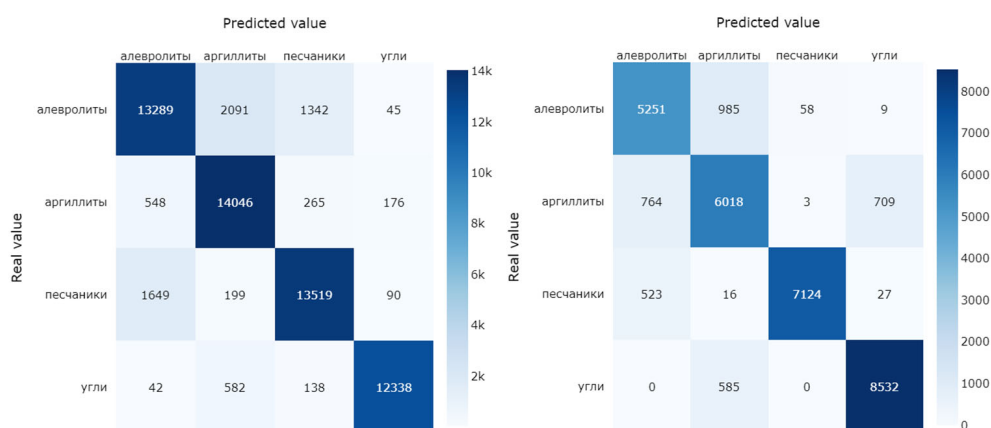


Рис. 2. Матрица ошибок модели ResNeXt101 32×4d (слева — обучающая выборка, справа — контрольная выборка)

Fig. 2. Confusion matrix of ResNeXt101 32×4d model (left — train subsample, right — validation subsample)

Ансамбль слабых классификаторов по данным графических идентификаторов

Для выбора оптимальных гиперпараметров модели типа XGBoost был выполнен случайный поиск с использованием перекрестной проверки (cross-validation K-fold = 10) с подбором оптимальных параметров регуляризации, высоты дерева, количества деревьев и других параметров. По результатам перебора 1 000 моделей была отобрана модель с наилучшим показателем взвешенной f1-меры на обучающей выборке. Точность классификации лучшей модели типа XGBoost на основе графических идентификаторов представлена в таблице 4 и на рис. 3.

Таблица 4

Качество классификации модели лучшей модели XGBoost на базе графических идентификаторов

Table 4

Classification quality of the best XGBoost model based on visual descriptors

Характеристика	алевролиты	аргиллиты	песчаники	угли	accuracy	macro avg	weighted avg
Обучающая выборка							
precision	0,72	0,76	0,83	0,91	0,80	0,80	0,80
recall	0,71	0,75	0,85	0,91	0,80	0,81	0,80
f1-score	0,71	0,75	0,84	0,91	0,80	0,80	0,80
Контрольная выборка							
precision	0,69	0,73	0,90	0,98	0,84	0,82	0,85
recall	0,82	0,77	0,92	0,83	0,84	0,83	0,84
f1-score	0,75	0,75	0,91	0,90	0,84	0,83	0,84




Рис. 3. Матрица ошибок лучшей модели XGBoost (слева — обучающая выборка, справа — контрольная выборка)

Fig. 3. Confusion matrix of best XGBoost model (left — train subsample, right — validation subsample)

Обсуждение

По результатам вычислений графических идентификаторов было выполнено сравнение получившихся значений для разных классов пород (таблица 5) и соотнесения их с исходными изображениями (рис. 1). Как мы видим, наиболее выделяющимся из 4 классов является уголь — с точки зрения цвета самая темная из рассматриваемых пород: низкие и равномерные значения во всех трех каналах R, G, B для среднего и первых двух наиболее доминирующих цветов, что подтверждается рис. 1.2D. Текстура угля имеет множество мелкой и слабовыраженной ряби (высокие значения энтропии, контраста, корреляции, с одновременно низкими значениями однородности), что видно по рис. 1.3D, и практически не содержит крупных и имеющих четкий контур включений (отрицательное число Эйлера и низкая энергия), что согласуется с рис. 1.4D.

Следующим классом, имеющим хорошо выраженные признаки, является песчаник. Цветовые характеристики песчаника указывают на преобладание более светлых тонов в изображении, чем у других классов: высокие и равномерные по каналам R, G, B значения для среднего и доминирующих цветов (рис. 1.1C и рис. 1.2C). Текстурные характеристики указывают на наличие небольших включений, т. к. число Эйлера относительно других классов небольшое, но уже является положительным в отличие от угля (таблица 5), что может быть продиктовано наличием горизонтальной трещины на фото (рис. 1.4C).

Примеры алевролитов и аргиллитов, представленных на рис. 1.1A и рис. 1.1B, не имели ярко выраженных отличий по цветовым характеристикам, однако существенно отличались по текстурным характеристикам (таблица 5). Аргиллиты имели самые низкие значения непохожести и контраста среди рассматриваемых примеров и самые высокие значения однородности, что соответствует рис. 1.3B. Высокие значения энергии и числа Эйлера для аргиллитов, скорее всего, не иллюстрируют признаков породы, а дают обобщенную характеристику конкретного примера, а именно наличие крупных светлых включений.

В целом же можно отметить, что графические идентификаторы дают численные характеристики, описывающие изображения, и позволяют очень хорошо разделять классы, имеющие существенные визуальные различия, такие как угли и песчаники, но могут иметь низкую классифицирующую способность при попытке разделения алевролитов от аргиллитов.

Также для анализа характера ошибок модели, показавшей наивысший результат по точности классификации на обучающей выборке (глубокая нейронная сеть ResNeXt101 32×4d), была произведена проверка в ручном режиме окон, результаты классификации которых не совпадали с исходной разметкой. По результатам такого анализа характер ошибок вызвал вопросы. Например,

Таблица 5

Значения графических идентификаторов для рассмотренных выше примеров изображений (рис. 1)

Table 5

Values of visual descriptors for the examples of images mentioned above (fig. 1)

	Алевролит	Аргиллит	Песчаник	Уголь
Цветовые характеристики (R, G, B)				
Средний	(185, 177, 174)	(131, 122, 117)	(143, 138, 132)	(53, 51, 52)
1-й доминирующий	(114, 106, 105)	(89, 78, 71)	(190, 186, 180)	(59, 55, 59)
2-й доминирующий	(109, 100, 100)	(106, 92, 83)	(182, 178, 171)	(63, 60, 64)
3-й доминирующий	(98, 90, 90)	(99, 86, 77)	(174, 169, 163)	(92, 88, 91)
Текстурные характеристики				
Энтропия	6,599	5,584	5,891	6,609
Число Эйлера	478	660	52	-541
Контраст	96,261; 260,296; 215,187; 229,941	26,219; 63,741; 51,767; 64,773	112,826; 257,976; 202,104; 219,524	232,740; 373,975; 245,088; 319,302
Непохожесть	7,154; 11,475; 10,327; 10,717	3,516; 5,139; 4,562; 5,251	8,193; 11,484; 10,071; 10,908	10,380; 13,708; 11,058; 12,497
Однородность	0,148; 0,100; 0,113; 0,109	0,279; 0,218; 0,242; 0,214	0,121; 0,092; 0,106; 0,096	0,123; 0,086; 0,106; 0,095
Энергия	0,022; 0,018; 0,019; 0,018	0,049; 0,043; 0,045; 0,042	0,027; 0,025; 0,026; 0,025	0,019; 0,016; 0,018; 0,017
Корреляция	0,922; 0,787; 0,825; 0,812	0,936; 0,844; 0,874; 0,842	0,832; 0,613; 0,697; 0,671	0,805; 0,687; 0,796; 0,733

для участков, размеченных как песчаник, алевролит и аргиллит, но распознанных как угли (рис. 4). В большинстве таких участков имеются углистые включения, площадь которых на рассматриваемом окне превосходила площадь класса, указанного специалистом, т. е. формально классификация была произведена корректно. В связи с этим была произведена оценка вероятностей для исследуемых 4 пород вдоль всего ствола керна, изображенного на одной фотографии в ручном режиме.

По результатам анализа вероятностей для исследуемых 4 пород вдоль всего ствола керна, после проверки профильными специалистами сформированного описания, был сделан вывод о том, что оценка, полученная моделью даже




Рис. 4. Матрица ошибок модели ResNeXt101 32×4d на обучающей выборке, представленная в виде случайных изображений

Fig. 4. Confusion matrix of model ResNeXt101 32×4d on train subsample presented by randomly selected images

при условии неполного совпадения с имеющимся описанием, выгруженным из корпоративной системы ИС «РН-Лаб» [1, 2], может быть обоснована. Так, например, на рис. 5 в верхней части ствола ядра наблюдается пересечение вероятностей песчаников и алевролитов высотой около 10 см. Данное пересечение получается в результате наличия включений алевролита на рассматриваемом участке. Однако в соответствии с регламентом описания и на усмотрение профильного специалиста данный участок может быть не выделен как отдельный слой по причине его малой мощности и отсутствия ценности для дальнейших исследований на наличие углеводородов.

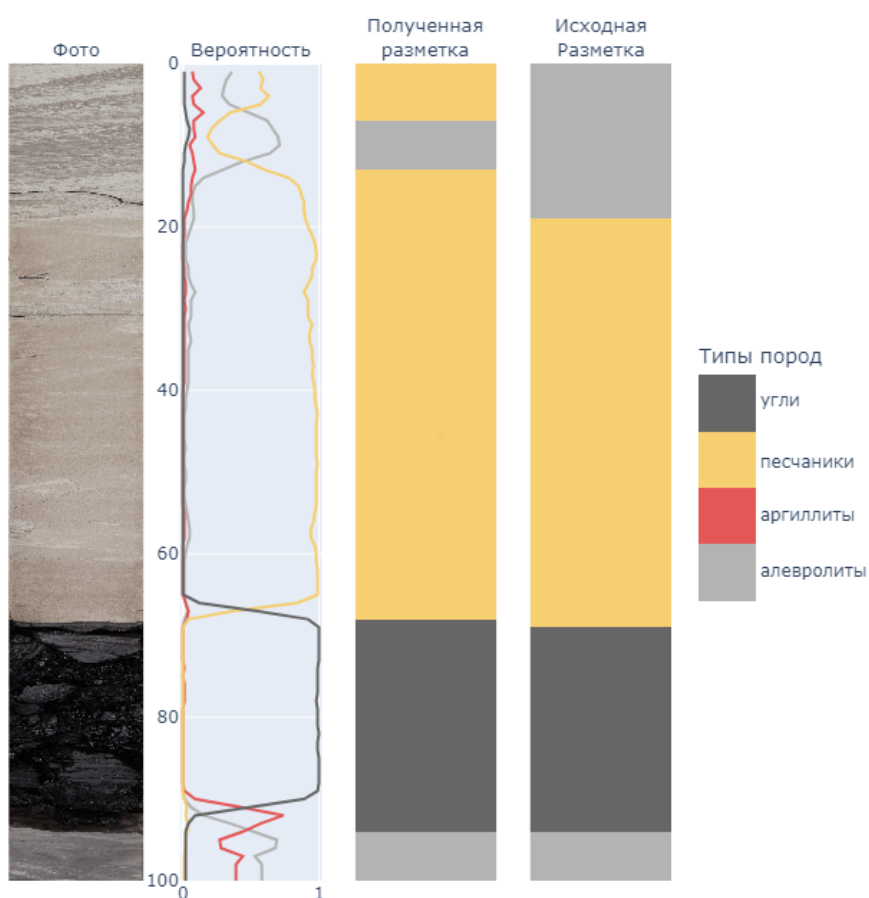


Рис. 5. Пример выделения слоев на исходной фотографии ядра

Fig. 5. Example of the layers detection in the original photo of the core

Таким образом, можно предположить, что при более детальном анализе ошибок полученных моделей (рис. 2, 3) могут быть найдены фрагменты ядра, имеющие корректное описание с точки зрения породы, но не представляющие ценности с точки зрения дальнейшего анализа (рис. 5).

Выводы

По результатам экспериментов можно утверждать, что обе модели показали достаточно высокую точность и могут быть применены на практике. Однако модель на основе сверточных нейронных сетей более чувствительна к неявным признакам, которые сложно извлечь, используя известные графические идентификаторы, что дает относительное сокращение ошибки классификации по $f1$ -мере на 12,5% даже без оптимизации гиперпараметров. Также данный подход имеет больший потенциал развития за счет отсутствия необходимости определения используемых признаков, т. к. глубокие нейронные сети за счет использования более сложных архитектур и операций свертки способны сами извлекать значимые признаки в процессе обучения и использовать их при применении. С другой стороны, подход на основе графических идентификаторов и ансамбля слабых классификаторов может быть использован без специализированных вычислительных мощностей (видеокарт). Таким образом, можно сделать вывод, что оба подхода могут быть применены на практике, но подход на основе глубоких нейронных сетей имеет больший потенциал развития с учетом увеличения мощностей видеокарт и снижения их стоимости по отношению к единице мощности.

СПИСОК ЛИТЕРАТУРЫ

1. РН-ЛАБ «Исследования полноразмерного керна»: свид. 2018661917 РФ об официальной регистрации программы для ЭВМ / В. З. Кузенков, Д. В. Каширских, С. В. Паромов, Ю. А. Рамазанов, М. Ф. Серкин. № 2018619071; заявл. 24.08.2018; опубл. 20.09.2018.
2. РН-ЛАБ «Литология»: свид. 2019616974 РФ об официальной регистрации программы для ЭВМ / Н. П. Девятка, Д. В. Каширских, С. В. Паромов, И. А. Вахрушева, В. З. Кузенков. № 2019615809; заявл. 21.05.2019; опубл. 03.06.2019.
3. Abashkin V. V. Quantitative analysis of whole core photos for continental oilfield of Western Siberia / V. V. Abashkin, I. A. Seleznev, A. A. Chertova, S. B. Istomin, D. V. Romanov, A. F. Samokhvalov // SPE Russian Petroleum Technology Conference. 2020. Paper SPE-202017-MS. DOI: 10.2118/202017-MS
4. Alzubaidi F. Automated lithology classification from drill core images using convolutional neural networks / F. Alzubaidi, P. Mostaghimi, P. Swietojanski, S. R. Clark, R. T. Armstrong // Journal of Petroleum Science and Engineering. 2021. Vol. 197. Art. 107933. DOI: 10.1016/j.petrol.2020.107933
5. Baraboshkin E. E. Deep convolutions for in-depth automated rock typing / E. E. Baraboshkin, L. S. Ismailova, D. M. Orlov, E. A. Zhukovskaya, G. A. Kalmykov, O. V. Khotylev, E. Yu. Baraboshkin, D. A. Koroteev // Computers & Geosciences. 2020. Vol. 135. Art. 104330. DOI: 10.1016/j.cageo.2019.104330
6. Chen T. XGBoost: A scalable tree boosting system / T. Chen, C. Guestrin // 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (New York, USA, 13-17 August, 2016). 2016. Pp. 785-794. DOI: 10.1145/2939672.2939785

7. Haralick R. M. Statistical and structural approaches to texture / R. M. Haralick // Proceedings of the IEEE. 1979. Vol. 67 (5). Pp. 786-804. DOI: 10.1109/PROC.1979.11328
8. Ivchenko A. V. Core photo lithological interpretation based on computer analyses / A. V. Ivchenko, E. E. Baraboshkin, L. S. Ismailova, D. M. Orlov, D. A. Koroteev, E. Yu. Baraboshkin // Proceedings of the IEEE Northwest Russia Conference on Mathematical Methods in Engineering and Technology (Saint-Petersburg, Russia, September 10-14, 2018). 2018. Vol. 8. Pp. 426-428.
9. Krizhevsky A. Learning Multiple Layers of Features from Tiny Images / A. Krizhevsky. University of Toronto, 2009.
10. Lin T.-Y. Microsoft COCO: Common objects in context / T.-Y. Lin, M. Maire, S. Belongie, J. Hays, P. Perona, D. Ramanan, P. Dollár, C. Zitnick // European Conference on Computer Vision. 2014. Pp. 740-755.
11. Lin X. The Euler Number study of image and its application / X. Lin, J. Ji, Y. Gu // 2nd IEEE Conference on Industrial Electronics and Applications. 2007. Pp. 910-912. DOI: 10.1109/ICIEA.2007.4318541
12. Lloyd S. Least squares quantization in PCM / S. Lloyd // IEEE Transactions on Information Theory. 1982. Vol. 28 (2). Pp. 129-137. DOI: 10.1109/TIT.1982.1056489
13. Löfstedt T. Gray-level invariant Haralick texture features / T. Löfstedt, P. Brynolfsson, T. Asklund, T. Nyholm, A. Garpebring // PLOS ONE. 2019. Vol. 14 (2). Art. e0212110. DOI: 10.1371/journal.pone.0212110
14. Paszke A. PyTorch: an imperative style, high-performance deep learning library / A. Paszke, S. Gross, F. Massa et al. // Advances in Neural Information Processing Systems. 2019. Vol. 32. Pp. 8024-8035.
15. Russakovsky O. ImageNet large scale visual recognition challenge / O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, A. Berg, L. Fei-Fei // International Journal of Computer Vision. 2015. Vol. 115. No. 3. Pp. 211-252. DOI: 10.1007/s11263-015-0816-y
16. Van der Walt S. Scikit-image: Image processing in python / S. van der Walt, J. L. Schönberger, J. Nunez-Iglesias, F. Boulogne, J. D. Warner, N. Yager, E. Gouillart, T. Yu // PeerJ. 2014. Vol. 1. Art. e453. DOI: 10.7717/peerj.453
17. Xie S. Aggregated residual transformations for deep neural networks / S. Xie, R. Girshick, P. Dollár, Z. Tu, K. He // IEEE Conference on Computer Vision and Pattern Recognition. 2017. Pp. 5987-5995. DOI: 10.1109/CVPR.2017.634
18. Yang W. Image segmentation based on gray level and local relative entropy two dimensional histogram / W. Yang, L. Cai, F. Wu // PLOS ONE. 2020. Vol. 15 (3). Art. e0229651. DOI: 10.1371/journal.pone.0229651

Sergey M. DYACHKOV¹
Olga A. YADRYSHNIKOVA²
Dmitriy V. POLYAKOV³
Nadezhda P. DEVYATKA⁴
Pavel I. CHERMYANIN⁵
Mikhail V. DMITRIEVSKIY⁶

UDC 004.891

AUTOMATIC ROCK IDENTIFICATION FROM CORE PHOTOS USING MODERN MACHINE LEARNING METHODS

- ¹ Chief Specialist, Department of Prototypes and Development Technologies,
Tyumen Petroleum Research Center
smdyachkov@tnc.rosneft.ru; ORCID: 0000-0002-3238-3259
- ² Cand. Sci. (Tech.), Chief Manager, Algorithmization Department,
Tyumen Petroleum Research Center
oayadrishnikova@tnc.rosneft.ru
- ³ Specialist, Department of Prototypes and Development Technologies,
Tyumen Petroleum Research Center
dvpolyakov3-tnk@tnc.rosneft.ru; ORCID: 0000-0002-9726-1375
- ⁴ Head of the Department of Lithological-Facies and Sedimentological Core Study,
Tyumen Petroleum Research Center
npdevyatka@tnc.rosneft.ru
- ⁵ Head of the Department of the Intelligent Technologies Development,
Tyumen Petroleum Research Center
pichermyanin2@tnc.rosneft.ru
- ⁶ Cand. Sci. (Phys.-Math.), Chief Manager,
High Technology Systems Development Department,
Tyumen Petroleum Research Center
mvdmitrievskiy@tnc.rosneft.ru

Citation: Dyachkov S. M., Yadryshnikova O. A., Polyakov D. V., Devyatka N. P., Chermyanin P. I., Dmitrievskiy M. V. 2021. "Automatic rock identification from core photos using modern machine learning methods". Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy, vol. 7, no. 4 (28), pp. 181-198.
DOI: 10.21684/2411-7978-2021-7-4-181-198

Abstract

Layer-by-layer description of the core is performed to understand the regularities of the structure of the geological section, predict the development of reservoirs, clarify stratigraphic boundaries and obtain calculation parameters for assessing hydrocarbon reserves. In this case, the name of the breed is one of the key parameters determined in the layer-by-layer description.

This paper presents a comparative analysis of two approaches to determining the breed using machine learning methods: based on graphical identifiers and convolutional neural networks.

The original sample contained photographs of core samples from the Tyumenskaya suite fields (8 fields, 15 wells, more than 2 km of core) under daylight. For the analysis, 4 main classes of rocks (siltstones, mudstones, sandstones, coals) were selected. For these rocks, windows of 5×5 cm were formed and compressed to 299×299 pixels. The total sample exceeded 90,000 windows: 70% — training sample (60,359 windows) and 30% — test (31,140 windows). The training and test samples contain photographs of core samples from different fields.

The comparison was made between convolutional neural networks (ResNet, ResNeXt, Inception, etc.) and a classifier (such as XGBoost) based on graphic identifiers of two types: color (average color, dominant colors) and texture (entropy, Euler's number, contrast, dissimilarity, uniformity, energy, correlation). According to the results of the experiments, the model based on convolutional neural networks turned out to be more sensitive to implicit features and made it possible to reduce the error in the weighted average f1-measure with respect to the ensemble of weak classifiers by 12.5% on the test sample even without optimization of hyperparameters.

Thus, we can conclude that the model based on convolutional neural networks is more sensitive to implicit features that are difficult to extract using known graphic identifiers. On the other hand, the approach based on graphic identifiers and an ensemble of weak classifiers can be used without specialized computing power (video cards).

Keywords

Core photography, convolutional neural networks, graphical identifiers, XGBoost, computer vision, geology, breed name.

DOI: 10.21684/2411-7978-2021-7-4-181-198

REFERENCES

1. Kuzenkov V., Kashirskikh D., Paromov S., Ramazanov Yu., Serkin M. (ed.). 2018. "Full-size core studies" RN-LAB: wit. 2018661917 the RF on the official registration of the computer program. No. 2018619071. [In Russian]
2. Devyatka N., Kashirskikh D., Paromov S., Vakhrusheva I., Kuzenkov V. (ed.). 2019. "Lithology" RN-LAB: wit. 2019616974 the RF on the official registration of the computer program. No. 2019616974. [In Russian]
3. Abashkin V., Seleznev I., Chertova A., Istomin S., Romanov D., Samokhvalov A. 2020. "Quantitative analysis of whole core photos for continental oilfield of Western Siberia". SPE Russian Petroleum Technology Conference. Paper SPE-202017-MS. DOI: 10.2118/202017-MS

4. Alzubaidi F., Mostaghimi P., Swietojanski P., Clark S., Armstrong R. 2021. "Automated lithology classification from drill core images using convolutional neural networks". *Journal of Petroleum Science and Engineering*, vol. 197, art. 107933. DOI: 10.1016/j.petrol.2020.107933
5. Baraboshkin E., Ismailova L., Orlov D., Zhukovskaya E. A., Kalmykov G. A., Khotylev O. V., Baraboshkin E. Yu., Koroteev D. A. 2019. "Deep Convolutions for In-Depth Automated Rock Typing". *Computers and Geosciences*, vol. 135, art. 104330. DOI: 10.1016/j.cageo.2019.104330
6. Chen T., Guestrin C. 2016. "XGBoost: a scalable tree boosting system". 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 785-794. DOI: 10.1145/2939672.2939785
7. Haralick R. M. 1979. "Statistical and structural approaches to texture". *Proceedings of the IEEE*, vol. 67, no. 5, pp. 786-804. DOI: 10.1109/PROC.1979.11328
8. Ivchenko V., Baraboshkin E., Ismailova L., Orlov D., Koroteev D., Baraboshkin E. Yu. 2018. "Core photo lithological interpretation based on computer analyses". *Proceedings of the IEEE Northwest Russia Conference on Mathematical Methods in Engineering and Technology*, vol. 8, pp. 426-428.
9. Krizhevsky A. 2009. "Learning multiple layers of features from tiny images". University of Toronto.
10. Lin T.-Y., Maire M., Belongie S., Hays J., Perona P., Ramanan D., Dollár P., Zitnick C. 2014. "Microsoft COCO: Common objects in context". *European Conference on Computer Vision*, pp. 740-755.
11. Lin X., Ji J., Gu Y. 2007. "The euler number study of image and its application". 2nd IEEE Conference on Industrial Electronics and Applications, pp. 910-912. DOI: 10.1109/ICIEA.2007.4318541
12. Lloyd S. 1982. "Least squares quantization in PCM". *IEEE Transactions on Information Theory*, vol. 28, no. 2, pp. 129-137. DOI: 10.1109/TIT.1982.1056489
13. Löfstedt T., Brynolfsson P., Asklund T., Nyholm T., Garpebring A. 2019. "Gray-level invariant Haralick texture features". *PLOS ONE*, vol. 14, no. 2, art. e0212110. DOI: 10.1371/journal.pone.0212110
14. Paszke A., Gross S., Massa F. et al. 2019. "PyTorch: an imperative style, high-performance deep learning library". *Advances in neural information processing systems*, vol. 32, pp. 8024-8035.
15. Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Huang Z., Karpathy A., Khosla A., Bernstein M., Berg A., Fei-Fei L. 2015. "ImageNet Large Scale Visual Recognition Challenge". *International Journal of Computer Vision (IJCV)*, vol. 115, no. 3, pp. 211-252. DOI: 10.1007/s11263-015-0816-y
16. Van der Walt S., Schönberger J. L., Nunez-Iglesias J., Boulogne F., Warner J. D., Yager N., Gouillart E., Yu T. 2014. "Scikit-image: image processing in Python". *PeerJ*, vol. 1, art. e453. DOI: 10.7717/peerj.453
17. Xie S., Girshick R., Dollár P., Tu Z., He K. 2017. "Aggregated residual transformations for deep neural networks". *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 5987-5995. DOI: 10.1109/CVPR.2017.634
18. Yang W., Cai L., Wu F. 2020. "Image segmentation based on gray level and local relative entropy two dimensional histogram". *PLOS ONE*, vol. 15, no. 3, art. e0229651. DOI: 10.1371/journal.pone.0229651