

НОВЫЕ МЕТОДЫ И ТЕХНОЛОГИИ ИЗУЧЕНИЯ ГЕОЛОГИЧЕСКОЙ СРЕДЫ НЕФТЕГАЗОНОСНЫХ БАССЕЙНОВ

Оригинальная статья

УДК: 551.7.022

EDN: PIANQX

Оптимизация построения литолого-фациальной модели с помощью нейронных сетей*

Д.К. Леонтьева ✉

ООО «РН-Геология Исследования Разработка», Россия, 625048, Тюмень, ул. Максима Горького, д. 42

Аннотация. *Актуальность.* Необходимость сокращения временных затрат и оптимизации работы квалифицированных специалистов при выполнении фациального анализа керна и снижения субъективности литолого-фациальной модели с переходом к унифицированным признакам макрофаций. *Цель работы.* Построение литолого-фациальной модели с последующим обоснованием геометрии залежи, используя седиментологический анализ кернового материала на основе нейронных сетей. *Материалы и методы.* Обработка и анализ данных литологического описания керна нейронной сетью с последующей актуализацией модели с учетом новых данных после последнего подсчета запасов исследуемого месторождения углеводородов. *Результаты.* Разработан алгоритм, позволяющий определить фацию по литологическому описанию керна без привлечения специалистов-седиментологов. Оценены ресурсы углеводородов прогнозируемой залежи на основе литофациальной модели, построенной с применением нейронных сетей. *Выводы.* Предлагаемый подход позволит сократить время на исследования керна, используя разработанный алгоритм, и повысит точность геологических моделей за счет вовлечения ранее не исследуемой информации.

Ключевые слова: седиментологический анализ, фация, нейронные сети, описание керна, геологическая модель, обучающая и тестируемая выборки

Финансирование: источники финансирования отсутствовали.

Для цитирования: Леонтьева Д.К. Оптимизация построения литолого-фациальной модели с помощью нейронных сетей // Актуальные проблемы нефти и газа. 2025. Т. 16, № 3. С. 362–371. EDN: PIANQX

* Статья написана на основе доклада на VII Всероссийской молодежной научной конференции «Актуальные проблемы нефти и газа», 16–18 октября 2024 г., Институт проблем нефти и газа Российской академии наук, Москва, Россия.

✉ Леонтьева Дарья Константиновна, DK_Sheveleva2@tnnc.rosneft.ru

© Леонтьева Д.К., 2025



Контент доступен под лицензией Creative Commons Attribution 4.0 License.

Введение

Седиментологические исследования являются основным способом изучения состава, строения, механизма возникновения и закономерности пространственного размещения осадочных пород. Результаты таких работ используются в том числе и в геологическом моделировании при подготовке проектно-технической документации, а также при выполнении подсчета запасов месторождений. Один специалист может описать до 10 м керна в день. В то же время ежегодный объем поступления керна в хранилище Тюменского нефтяного научного центра в среднем составляет до 11 км, из которого за последние два года порядка 90% было отправлено на седиментологические исследования. Подобные работы требуют определенных трудозатрат и большого штата квалифицированных специалистов.

Целью исследования является оптимизация процесса построения литолого-фациальной модели за счет нейронных сетей для седиментологического анализа керна, что не заменит специалиста, но позволит сократить временные затраты.

Материалы и методы

При решении поставленной задачи был разработан алгоритм на основе нейронных сетей для построения геологической модели одного из месторождений углеводородов (УВ) в Западной Сибири. Полигоном для апробации стали пять пластов яковлевской свиты апт-альбского возраста, сформированные в условиях прибрежной равнины, временами заливавшейся морем.

На 2024 год среди всех скважин на месторождении, вскрывших данные отложения, по 16 имеются материалы литологического описания керна, суммарный объем которого составляет 5 пог. км. Из этого объема по данным девяти скважин, что составило 3 пог. км, выполнен литолого-фациальный анализ с выделением двух фациальных комплексов: аллювиального и прибрежно-континентального.

Работа проводилась при помощи программного обеспечения Anaconda и JPT Notebook на языке программирования Python.

Результаты и обсуждение

Для построения модели было проведено объединение первично выделенных фаций в пять макрофаций [1, 2]. Основные перспективы изучаемых отложений связаны со значительным объемом коллекторов с высокими значениями фильтрационно-емкостных свойств, которые представлены макрофацией речного канала. Эта макрофация сложена песчаниками разномерными, алевроитистыми или переслаиванием алевролитов мелкозернистых и песчаников с пологоволнистой, разнонаправленной слоистостью и сдвоенными слоями. Менее перспективная – макрофация песчаных приливно-отливных отмелей – представлена песчаниками мелко-среднезернистыми, от светло-серых до темно-серых, с кривой слоистостью, рябью течения, растительным детритом и биотурбацией. Остальные фации содержат незначительную долю коллекторов.

Для проверки работы алгоритма был выбран пласт, представленный отложениями прибрежно-континентального комплекса. В тестируемую выборку по данному пласту вошло семь скважин с суммарным объемом керна 1,5 пог. км.

Подготовка данных к работе заключалась в сборе имеющегося подробного седиментологического описания керна, выполненного специалистами-седиментологами, приведению к единому

формату и исключению разночтений. Данные сформированы в таблицу, где в каждую колонку записан конкретный признак, образец формата данных приведен в табл. 1.

Табл. 1. Формат входных данных обучающей выборки

Table 1. Input data format for the training set

Порода	Структура	Текстура	Цвет	Слойки, линзочки	Признак n	Код фация
Алевриты песчаные	Крупно-зернистая	Однородная, горизонтальная	От серого до коричневого-серого	Прослои алевритита	...	STF

Выборка сформирована в таблицу MS Excel, в которой перечислено 11 ключевых характеристик для данных отложений: порода, структура, текстура, цвет, наличие слойков и линзочек, присутствие растительных остатков, разновидность ихнофоссилий, биотурбация, деформации, включения и конкреции, контакты слоев, а также переданный специалистами код фаций. Подобранные качественные признаки керна выбраны как основные характеристики распознаваемой обстановки осадконакопления, по которым можно определить диагностические особенности и принадлежность к фациям [3–5].

Обучающая выборка включает проанализированные специалистами данные

литолого-фациального описания керна по пяти пластам, на которых алгоритм должен пройти обучение. С помощью программного обеспечения Anaconda и JPT Notebook на языке программирования Python написан программный код.

В основе алгоритма заложена модель обучения Decision trees («Дерево решений»), см. рис. 1, которая представляет данные в виде иерархической системы. При определении каждой фации в узлах схемы происходит распределение данных на несколько переменных, одна из которых является характерным признаком. Далее разветвление происходит до момента, когда все признаки будут проанализированы [6–8].




Рис. 1. Схематичный фрагмент алгоритма модели обучения Decision Tree («Дерево решений»)

Fig. 1. Schematic fragment of the Decision Tree learning model algorithm

После загрузки обучающей выборки формируются нейронные связи между используемыми данными, производится расчет, а также донастройка нейросети для повышения точности прогноза, если результат не устраивает. Для большей точности алгоритм проверяют по метрике, которая характеризует качество модели по всем классам.

Доля верно предсказанной фации среди всех случаев определения интересующей фации называется точностью. Полнота – это доля верно предсказанной фации среди всех предсказаний.

Данная методика позволяет увидеть ошибку в определении каждого класса и в дальнейшем скорректировать значимость параметров. Чем ниже величина ошибки, тем лучше настроен алгоритм. При проверке алгоритма использована контрольная выборка – 25% образцов из 144, вошедших в обучающую выборку. Анализ результатов показал хорошую сходимость точности от 100% до 71% с максимальной ошибкой в 29% и полноте от 100% до 78% с максимальной ошибкой 22%. Наиболее вероятны ошибки в тех областях осадконакопления, которые находятся в переходной зоне между соседними фациями, и поэтому имеют смешанные свойства двух фаций [9, 10].

По итогу работы обученный алгоритм показал хорошую сходимость в рамках допустимой ошибки. Стоит отметить, что после анализа алгоритм готов к многократному использованию. Переобучение и настройка потребуется только при большой величине ошибки, либо при распознавании другого фациального комплекса, не упомянутого в данной работе [11]. Время, затраченное на создание и отладку алгоритма составило 11 дней,

а сам расчет происходит в течение нескольких минут.

После завершения обучения и настройки подгружается тестируемая выборка: материалы литологического описания керна без седиментологического анализа и выделения фаций, которые алгоритму необходимо будет провести и выделить самостоятельно.

Из всех пяти основных пластов сформирована обучающая выборка, а по пласту, выбранному для проверки алгоритмом, составлена тестируемая выборка. В результате для каждой скважины в интервале пласта выделены преобладающие фации. Полученная информация была использована при построении литолого-фациальной модели и для последующего прогноза распространения коллекторов моделируемого пласта [12–14].

Объектом геологического моделирования является залежь нефти, прогнозируемая в изучаемом пласте по результатам эксплуатационного бурения транзитного фонда скважин. В ходе моделирования залежи при распределении литологического состава в трехмерной области учтены фациальные зоны, полученные с помощью обработки керновых данных нейронной сетью. По материалам сейсморазведки выделены осевые линии русел, они преобразованы в карты азимутов и использованы в качестве тренда для распределения фаций. На сейсмических разрезах отмечается наличие русловых врезов [15].

На карте поверхности водонефтяного контакта (ВНК) по скважинам наблюдается подъем уровня контакта в сторону ухудшенных маломощных коллекторов и погружение его в области развития русла.

Такое поведение объясняется изменением фильтрационно-емкостных свойств, связанных со сменой фаций [16, 17]. Основной нефтенасыщенный объем связан с фацией русловых отложений. На западе залежи развита фация солоноватых маршей, которая слабо изучена бурением.

В данном районе пробурена одна скважина с эффективной толщиной 0,5 м. На западе залежи ожидаются аналогичные маломощные коллекторы (рис. 2) Таким образом, западная часть является зоной возможного неподтверждения коллекторов.




Рис. 2. Фациальная карта изучаемой залежи

Fig. 2. Facies map of the studied reservoir

Распространение фациальных зон в пространстве объясняет изменение фильтрационно-емкостных свойств, распределение коллекторов и уровень ВНК. Детализация фациального строения анализируемого пласта позволила выделить как перспективные зоны в оконтуренной залежи, так и зоны рисков.

Заключение

– Благодаря разработанному алгоритму в работу вовлечена ранее неиспользуемая информация: изначально для нужд литолого-фациальной модели было доступно девять скважин с седиментологическим

описанием, а благодаря описанному алгоритму дополнительно привлечены данные керна еще по шести скважинам, что повысило плотность исходных данных на 67%.

– Применение цифровых технологий позволило сократить время на исследования керна одним специалистом в рамках данной работы на 25%.

– Разработан и протестирован алгоритм, позволяющий выполнить седиментологический анализ и снизить субъективность выделения фаций, а сам программный код готов к многократному использованию.

– На основе результатов работы разработанного алгоритма построена литолого-фациальная модель.

– Выполнена оценка ресурсов УВ прогнозируемой в изучаемом пласте залежи и выполнен прогноз рисков при разработке. В западной части залежи ожидается зона неподтверждения коллекторов, связанная с отложениями солоноватых маршей.

– Внедрение процессов автоматизации позволит оптимизировать процесс анализа и оценки фаций, а также сформировать базу данных по активам Компании ООО «РН-ГИР» для подбора объектов-аналогов с целью использования их керновых материалов для обучения выборки на месторождениях, где собственные данные седиментологического описания окажутся недостаточными.

Вклад автора

Д.К. Леонтьева – концептуализация, администрирование данных, методология, проведение исследования, визуализация, создание рукописи и ее редактирование.

Конфликт интересов

Автор заявляет об отсутствии конфликта интересов.

Список источников

1. Грищенко М.А. Алгоритм работы и создание 1D фациальной модели по данным керна и ГИС продуктивных пластов в меловом и юрском нефтегазоносных комплексах Западной Сибири // Экспозиция Нефть Газ. 2022. № 8(93). С. 22–28. <https://doi.org/10.24412/2076-6785-2022-8-22-28>
2. Топалова Т.Э., Кайдалина Т.Е., Грищенко М.А. и др. Уточнение геологического строения низкопроницаемых туронских отложений Харампурского нефтегазоконденсатного месторождения по результатам комплексного литофациального анализа для оптимизации проекта разработки // Геология нефти и газа. 2020. № 2 С. 95–106. <https://doi.org/10.31087/0016-7894-2020-2-95-106>
3. Титенков А.С., Утяшев Ю.Н., Евдоцук А.А. и др. Изучение геологического строения верхнеюрских отложений Тагульского месторождения в процессе обоснования эксплуатационного бурения // Известия высших учебных заведений. Нефть и газ. 2021. № 5(149). С. 85–97. <https://doi.org/10.31660/0445-0108-2021-5-85-97>
4. Казанцев Г.В. Комплексный анализ пластов прибрежно-континентального генезиса с целью уточнения геологической модели // Георесурсы. 2024. Т. 26, № 3. С. 13–19. <https://doi.org/10.18599/grs.2024.3.2>
5. Шафрова Д.В., Соколова О.А. Биотурбация среднеюрских и нижнемеловых терригенных отложений Западной Сибири // Экспозиция Нефть Газ. 2024. № 7(108). С. 61–69. <https://doi.org/10.24412/2076-6785-2024-7-61-69>
6. Парасич А.В., Парасич В.А., Парасич И.В. Формирование обучающей выборки в задачах машинного обучения. Обзор // Информационно-управляющие системы. 2021. № 4(113). С. 61–70. <https://doi.org/10.31799/1684-8853-2021-4-61-70>
7. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2017. Т. 6, № 3. С. 28–59. <https://doi.org/10.14529/cmse170303>

8. *Шарапатов А., Садуов А., Асирбек Н.* Сравнительный анализ возможностей алгоритмов машинного обучения в геологии // Горный журнал Казахстана. 2023. № 11(223). С. 14–20. <https://doi.org/10.48498/minmag.2023.223.11.002>
9. *Сахнюк В.И., Новиков Е.В., Шарифуллин А.М. и др.* Применение методов машинного обучения в обработке данных геофизических исследований скважин отложений викуловской свиты // Георесурсы. 2022. Т. 24, № 2. С. 230–238. <https://doi.org/10.18599/grs.2022.2.21>
10. *Jiao S.R., Song J., Liu B.* A review of decision tree classification algorithms for continuous variables // Journal of Physics: Conference Series. 2020. Vol. 1651, No. 1. P. 012083. <https://doi.org/10.1088/1742-6596/1651/1/012083>
11. *Priyanka, Kumar D.* Decision tree classifier: a detailed survey // International Journal of Information and Decision Sciences. 2020. Vol. 12, No. 3. P. 246–269. <https://doi.org/10.1504/IJIDS.2020.108141>
12. *Генераленко О.С., Шелепов И.В., Ермакова О.Э. и др.* Интегрированный подход к построению геологических моделей на основе фациального анализа // Георесурсы. 2024. Т. 26, № 3. С. 33–42. <https://doi.org/10.18599/grs.2024.3.5>
13. *Грищенко М.А.* Результаты работ по созданию фациальных моделей и проблемы прогноза межскважинного пространства продуктивных пластов в меловом и юрском нефтегазоносных комплексах Западной Сибири // Экспозиция Нефть Газ. 2022. № 8. С. 30–35. <https://doi.org/10.24412/2076-6785-2022-8-30-35>
14. *Черепкова А.А., Бусуек Е.С., Кураш Т.П. и др.* Мультидисциплинарный подход к геологическому моделированию пластов В10-13, осложненных первичными особенностями осадконакопления и вторичными преобразованиями // Экспозиция Нефть Газ. 2024. № 7(108). С. 25–33. <https://doi.org/10.24412/2076-6785-2024-7-25-33>
15. *Никифоров В.В., Шарафутдинов А.Р., Шабрин Н.В., Чибисов А.В.* Уточнение литолого-фациального строения юрско-нижнемеловых отложений на основе спектральной декомпозиции // Геология. Известия Отделения наук о Земле и природных ресурсов. 2024. № 2(35). С. 49–65. <https://doi.org/10.24412/2949-4052-2024-2-49-65>
16. *Калинин В.Ф.* К вопросу определения размеров переходной зоны на границе водонефтяного контакта в гидрофильных и гидрофобных коллекторах // Недра Поволжья и Прикаспия. 2021. Вып. 103. С. 11–41. <https://doi.org/10.24411/1997-8316-2021-11032>
17. *Егорова А.Д., Исакова Т.Г., Дьяконова Т.Ф., Калмыков Г.А.* Моделирование газонефтяной переходной зоны по данным керны и геофизических исследований скважин // Геофизика. 2023. № 3. С. 78–84. <https://doi.org/10.34926/geo.2023.24.89.011>

Информация об авторе

Дарья Константиновна Леонтьева – ведущий специалист, ООО «РН-Геология Исследования Разработка», Тюмень, Россия; <https://orcid.org/0009-0003-8294-1583>; e-mail: DK_Sheveleva2@tnnc.rosneft.ru

Поступила в редакцию 08.09.2025

Принята к публикации 28.10.2025

NEW METHODS AND TECHNOLOGIES OF STUDYING THE GEOLOGICAL ENVIRONMENT OF OIL AND GAS BASINS

Original article

Neural network-based optimization of lithofacies model building process*

Daria K. Leontyeva ✉

RN-Geology Research Development LLC, 42 Maksima Gorkogo St., Tyumen, 625048, Russia

Abstract. *Background.* There is a need to reduce time costs and optimize the work of qualified experts during the core-based facies analysis and to decrease the subjectivity of the lithofacies model with the transition to standardized features of macrofacies. *Objective.* To build a lithofacies model followed by justification of the reservoir geometry using sedimentological analysis of core material based on neural networks. *Materials and methods.* Processing and analysis of the core lithological description data using a neural network with a model update including new data after the last estimation of reserves of the studied hydrocarbon field. *Results.* An algorithm allowing to determine the facies based on the lithological description of the core without the involvement of sedimentologists was developed. Hydrocarbon resources of the reservoir in question were estimated based on the lithofacies model that was built using neural networks. *Conclusions.* The proposed approach will reduce the time for core studies by using the developed algorithm and will increase the accuracy of geological models due to the involvement of previously unstudied information.

Keywords: sedimentological analysis, facies, neural networks, core description, geological model, training and testing sets

Funding: the work received no funding.

For citation: Leontyeva D.K. Neural network-based optimization of lithofacies model building process. *Actual Problems of Oil and Gas*. 2025. Vol. 16, No. 3. P. 362–371. (In Russ.).

* The article is based on the report presented at the 7th All-Russian Youth Scientific Conference “Actual Problems of Oil and Gas”, 16–18 October 2024, Oil and Gas Research Institute, Russian Academy of Sciences, Moscow, Russia.

✉ Daria K. Leontyeva, DK_Sheveleva2@tnnc.rosneft.ru

© Leontyeva D.K., 2025



The content is available under Creative Commons Attribution 4.0 License.

Author contributions

Daria K. Leonteva – conceptualization, data curation, methodology, investigation, visualization, writing – review & editing.

Conflict of interests

The author declares no conflict of interests.

References

1. Grishchenko M.A. Algorithm for operation and creation of 1D facies model based on core data and well logs of productive formations in the Cretaceous and Jurassic oil and gas reservoirs of Western Siberia. *Exposition Oil Gas*. 2022. No. 8(93). P. 22–28. (In Russ.). <https://doi.org/10.24412/2076-6785-2022-8-22-28>
2. Topalova T.E., Kaidalina T.E., Grishchenko M.A. et al. Results of integrated lithofacies analysis for optimisation of Field Development Plan: updating geological structure of low-permeable Turonian formations in the Kharampursky oil and gas condensate field. *Geologiya nefi i gaza*. 2020. No. 2. P. 95–106. (In Russ.). <https://doi.org/10.31087/0016-7894-2020-2-95-106>
3. Titenkov A.S., Utyashev Yu.N., Evdoshchuk A.A. et al. Comprehensive study of the geological structure Verkhneyakovlev deposits of the Tagul field in the process of justifications for operational drilling. *Oil and Gas Studies*. 2021. No. 5(149). P. 85–97. (In Russ.). <https://doi.org/10.31660/0445-0108-2021-5-85-97>
4. Kazantsev G.V. Complex analysis of coastal-continental geological formations for the clarification of geological model. *Georesursy*. 2024. Vol. 26, No. 3. P. 13–19. (In Russ.). <https://doi.org/10.18599/grs.2024.3.2>
5. Shafronova D.V., Sokolova O.A. Bioturbation of Middle Jurassic and Lower Cretaceous terrigenous sediments of Western Siberia. *Exposition Oil Gas*. 2024. No. 7(108). P. 61–69. (In Russ.). <https://doi.org/10.24412/2076-6785-2024-7-61-69>
6. Parasich A.V., Parasich V.A., Parasich I.V. Training set formation in machine learning tasks. Survey. *Information Control Systems*. 2021. No. 4(113). P. 61–70. (In Russ.). <https://doi.org/10.31799/1684-8853-2021-4-61-70>
7. Sozykin A.V. An overview of methods for deep learning in neural networks. *Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering*. 2017. Vol. 6, No. 3. P. 28–59. (In Russ.). <https://doi.org/10.14529/cmse170303>
8. Sharapatov A., Saduov A., Asirbek N. Comparative analysis of the capabilities of machine learning and deep learning algorithms in geology. *Mining Journal of Kazakhstan*. 2023. No. 11(223). P. 14–20. (In Russ.). <https://doi.org/10.48498/minmag.2023.223.11.002>
9. Sakhnyuk V.I., Novikov E.V., Sharifullin A.M. et al. Machine learning applications for well-logging interpretation of the Vikulov Formation. *Georesursy*. 2022. Vol. 24, No. 2. P. 230–238. (In Russ.). <https://doi.org/10.18599/grs.2022.2.21>
10. Jiao S.R., Song J., Liu B. A review of decision tree classification algorithms for continuous variables. *Journal of Physics: Conference Series*. 2020. Vol. 1651, No. 1. P. 012083. <https://doi.org/10.1088/1742-6596/1651/1/012083>

11. Priyanka, Kumar D. Decision tree classifier: a detailed survey. *International Journal of Information and Decision Sciences*. 2020. Vol. 12, No. 3. P. 246–269. <https://doi.org/10.1504/IJIDS.2020.108141>
12. Generalenko O.S., Shelepov I.V., Ermakova O.E. et al. Integrated approach to the construction of geological models based on facies analysis. *Georesursy*. 2024. Vol. 26, No. 3. P. 33–42. (In Russ.). <https://doi.org/10.18599/grs.2024.3.5>
13. Grishchenko M.A. Results of facies modeling and productive formations cross-well prediction problems in the Cretaceous and Jurassic oil and gas reservoirs of Western Siberia. *Exposition Oil Gas*. 2022. No. 8(93). P. 30–35. (In Russ.). <https://doi.org/10.24412/2076-6785-2022-8-30-35>
14. Cherepkova A.A., Busuyek E.S., Kurash T.P. et al. Cross-functional approach to geological modeling of the horizon V10-13 complicated with initial sedimentation characteristics and secondary transformations. *Exposition Oil Gas*. 2024. No. 7(108). P. 25–33. (In Russ.). <https://doi.org/10.24412/2076-6785-2024-7-25-33>
15. Nikiforov V.V., Sharafutdinov A.R., Shabrin N.V., Chibisov, A.V. Update the lithofacies structure based of spectral decomposition. *Geology. The Bulletin of the Department of Earth Sciences and Natural Resources*. 2024. No. 2(35). P. 49–65. (In Russ.). <https://doi.org/10.24412/2949-4052-2024-2-49-65>
16. Kalinin V.F. To the question of determining the transition zone sizes at the boundary of a water-oil contact in hydrophilic and hydrophobic collectors. *Volga and Pre-Caspian Region Resources*. 2021. No. 103. P. 11–41. (In Russ.). <https://doi.org/10.24411/1997-8316-2021-11032>
17. Egorova A.D., Isakova T.G., Dyakonova T.F., Kalmykov G.A. Modeling of the gas-oil transition saturation zone based on core data and well logging. *Geophysics*. 2023. No. 3. P. 78–84. (In Russ.). <https://doi.org/10.34926/geo.2023.24.89.011>

Information about the author

Daria K. Leontyeva – Leading Specialist, RN-Geology Research Development LLC, Tyumen, Russia; <https://orcid.org/0009-0003-8294-1583>; e-mail: DK_Sheveleva2@tnnc.rosneft.ru

Received 8 September 2025

Accepted 28 October 2025