



Применение методов машинного обучения в нефтегазовой геологии и геофизике: от теоретических основ к практической реализации

Н. Р. Медведев*, С. Р. Бембель, М. Е. Савина

Тюменский индустриальный университет, Тюмень, Российская Федерация
**medvedevnr@gmail.com*

Аннотация. В статье представлен систематизированный анализ современных методов машинного обучения и их практического применения для решения ключевых задач нефтегазовой геологии и геофизики. Рассмотрены преимущества и ограничения основных архитектур нейронных сетей, включая сверточные (CNN), рекуррентные (RNN) и глубокие сети прямого распространения (DNN). Особое внимание удалено интеграции данных различных типов и масштабов — от сейсмических исследований до керна и геофизических исследований скважин. В качестве практического инструментария рассмотрена платформа машинного обучения Orange с открытым исходным кодом, продемонстрировавшая высокую эффективность для задач анализа и визуализации геологических данных. На реальных примерах показано, как применение машинного обучения позволяет существенно повысить точность интерпретации, сократить временные затраты и минимизировать субъективный фактор. Делается вывод о переходе нейросетевых технологий из разряда экспериментальных в категорию обязательных инструментов для повышения экономической эффективности геолого-разведочных работ.

Ключевые слова: искусственный интеллект, машинное обучение, нейронные сети, сейсмическая интерпретация, прогнозирование коллекторских свойств, классификация лиофаций, платформа Orange, нефтегазовая геофизика

Для цитирования: Медведев, Н. Р. Применение методов машинного обучения в нефтегазовой геологии и геофизике: от теоретических основ к практической реализации / Н. Р. Медведев, С. Р. Бембель, М. Е. Савина. – DOI 10.31660/0445-0108-2025-6-57-65 // Известия высших учебных заведений. Нефть и газ. – 2025. – № 6. – С. 57–65. – EDN: ZKDDBT

Application of machine learning methods in oil and gas geology and geophysics: from theoretical foundations to practical implementation

Nikolay R. Medvedev*, Sergey R. Bembel, Marina E. Savina

Industrial University of Tyumen, Tyumen, Russian Federation
**medvedevnr@gmail.com*

Abstract. This paper presents a systematic analysis of modern machine learning methods and their practical applications in solving key problems in petroleum geology and geophysics. This study discusses the advantages and limitations of major neural network architectures, including convolutional neural networks (CNNs), recurrent neural networks (RNNs), and deep feedforward networks (RNNs), and deep feedforward networks (DNNs). The authors of this paper paid special attention

to the integration of various types and scales of data, ranging from seismic surveys to core samples and borehole geophysical measurements. The open-source machine learning platform, Orange, is highlighted as a very effective tool for geological data analysis and visualization tasks. Real-world examples illustrate how machine learning can significantly enhance interpretation accuracy, reduce time costs, and minimize subjective bias. The paper concludes that neural network technologies are transitioning from experimental tools to binding instruments for improving the economic efficiency of geological exploration activities.

Key words: artificial intelligence, machine learning, neural networks, seismic interpretation, reservoir property prediction, lithophase classification, Orange platform, oil and gas geophysics

For citation: Medvedev, N. R., Bembel, S. R., & Savina, M. E. (2025). Application of machine learning methods in oil and gas geology and geophysics: from theoretical foundations to practical implementation // Oil and Gas Studies, (6), pp. 57-65. (In Russian). DOI: 10.31660/0445-0108-2025-6-57-65

Введение

Современный этап развития нефтегазовой отрасли характеризуется усложнением поисковых объектов, увеличением доли трудноизвлекаемых запасов и необходимостью повышения эффективности геологоразведочных работ в условиях экономической неопределенности. Эти вызовы стимулируют активный поиск и внедрение цифровых технологий, среди которых методы искусственного интеллекта и машинного обучения занимают одно из центральных мест.

Способность машинного обучения выявлять сложные, нелинейные закономерности в многомерных и зашумленных данных делает его идеальным инструментом для решения широкого спектра геологических и геофизических задач — от автоматизированной обработки сейсмических данных и классификации фаций до прогнозирования коллекторских свойств и оценки рисков бурения.

Цель работы — провести обзор современных возможностей применения методов машинного обучения в нефтегазовой геологии и геофизике, систематизировать основные типы решаемых задач и на практических примерах продемонстрировать эффективность их применения.

1. Теоретические основы и архитектуры нейронных сетей

В современной практике геолого-геофизических исследований наибольшее применение нашли три основных типа архитектур нейронных сетей, каждый из которых имеет специфические области эффективного применения.

Сверточные нейронные сети (Convolutional Neural Networks, CNN) наиболее часто используются в обработке и интерпретации сейсмических данных, которые по своей природе являются двумерными или трехмерными изображениями [8]. CNN эффективны для автоматического выделения геологических объектов (сбросов, разломов, каналов, карбонатных построек), сейсмического фациального анализа, а также для подавления шумов и повышения разрешения сейсмических данных.

Рекуррентные нейронные сети (Recurrent Neural Networks, RNN), в особенности архитектуры с долгой краткосрочной памятью (LSTM), идеально подходят для работы с последовательными данными, такими как кривые каротажа и данные керна [9]. Благодаря наличию «памяти» они успешно применяются для корреляции геологических разрезов, прогнозирования пропущенных данных и анализа временных рядов.

Глубокие сети прямого распространения (Deep Neural Networks, DNN) широко используются для решения задач регрессии и классификации по табличным данным [6]. Наиболее востребованные приложения включают прогнозирование фильтрационно-емкостных свойств (пористость, проницаемость, нефтенасыщенность) и классификацию лиофаций по комплексу геофизических данных.

2. Обзор практического применения в отечественной практике

Эффективность методов машинного обучения подтверждается многочисленными исследованиями российских и зарубежных специалистов. В области петрографии значительные результаты получены Е. А. Василёновой [1], которая продемонстрировала методику классификации минеральных компонентов гранитоидов по макроизображениям с использованием машинного обучения. В своем исследовании автор применила алгоритм ансамбля решающих деревьев (Fast Random Forest) в связке с плагином Trainable Weka Segmentation для программной среды ImageJ. На основе подготовленной базы данных из областей интереса (ROI) для породообразующих минералов (кварца, калиевого полевого шпата, пластика и биотита) была достигнута высокая точность классификации с ошибкой от 3,5 до 6,3 %.

Ключевое преимущество подхода заключается в использовании цветовых параметров минералов в качестве надежного критерия для идентификации, что особенно актуально для разделения калиевых полевых шпатов и пластика. Метод также позволил осуществить последующий количественный анализ — определить процентное содержание и количество зерен каждого минерала, что открывает возможности для автоматизированного анализа структуры горных пород (рис. 1).

Значительный вклад в применение методов машинного обучения в буровых операциях внесен В. А. Старцевым, Г. В. Буслаевым и А. В. Конопляниковым [4], которые провели комплексный анализ мирового опыта использования данных технологий при бурении нефтяных и газовых скважин. Авторы систематизировали применение различных архитектур нейронных сетей — от многослойных персепtronов до LSTM — для решения ключевых технологических задач. Особое внимание удалено прогнозированию критических осложнений, включая прихваты бурильной колонны, поглощения бурового раствора и газонефтеводопроявления, где точность моделей достигает 85–92 %.

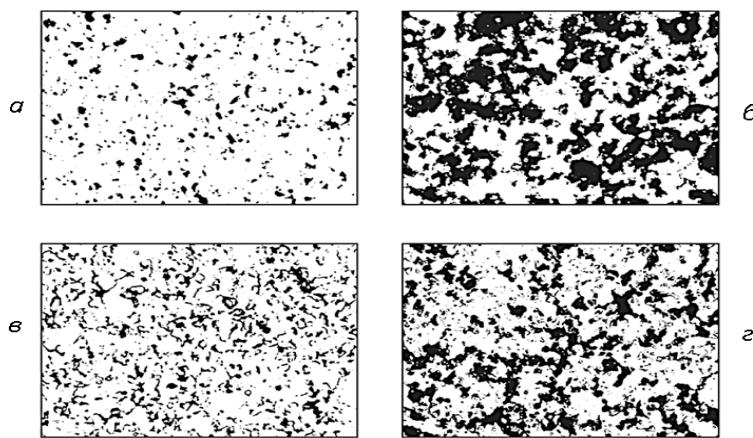


Рис. 1. Создание масок минералов гранита по классификационным изображениям:
а — биотит; б — калиевый полевой шпат; в — пластиоклаз; г — кварц [1]

Практическая ценность работы подчеркивается детальным описанием применения алгоритмов XGBoost, Light GBM и CatBoost для обработки телеметрических данных в реальном времени. Авторы также предложили концепцию интегрированной интеллектуальной модели бурения, включающую четыре уровня цифровизации — от инструментального контроля до управлеченческой трансформации (рис. 2), что позволяет приблизиться к «техническому пределу» эффективности буровых операций [4].

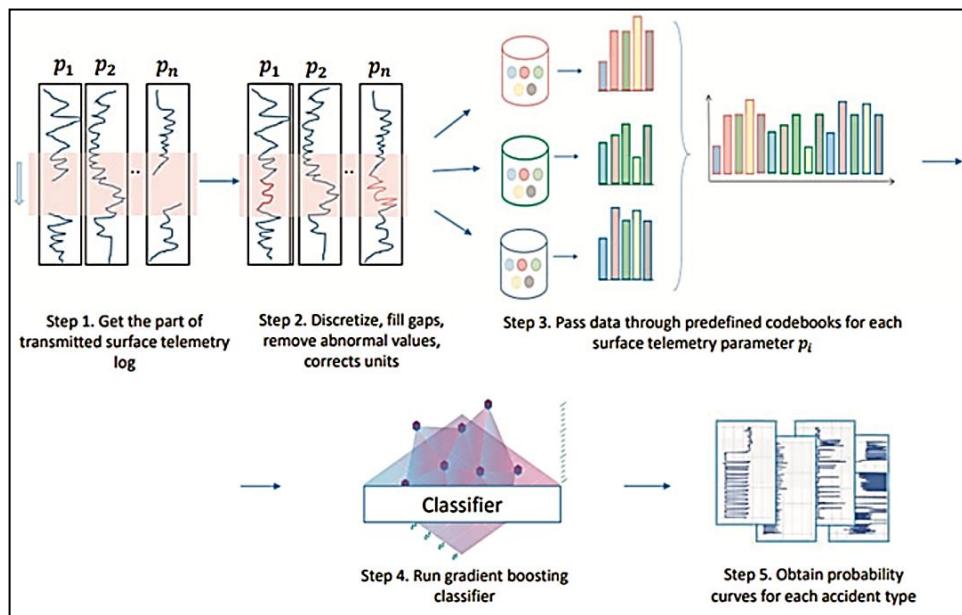


Рис. 2. Принцип действия Bag – of-features [4]

Результаты в области применения машинного обучения для моделирования сложных карбонатных коллекторов получены Д. В. Потехиным и С. В. Галкиным [3]. В исследовании пермокарбоновой залежи Усинского месторождения авторы успешно реализовали комплексный подход 3D-геологического моделирования с использованием нейронных сетей Левенберга-Марквардта. На первом этапе была решена задача автоматизированного выделения коллекторов по данным ГИС с точностью 95 % при полном комплексе методов исследований. На втором этапе проведена классификация литотипов пород по системе Данхема с последующим расчетом параметров трещиноватости.

Особый практический интерес представляет разработанная методика оценки трещинной проницаемости через плотность и раскрытие трещин, что позволило создать модель двойной пористости для трещиннокавернозных коллекторов. Полученные алгоритмы применены к 983 скважинам без отбора керна, что значительно повысило детальность геологической модели. Ошибка прогнозирования составила 3–5 %, подтверждая высокую надежность метода. Результаты работы внедрены в действующую цифровую 3D-геолого-технологическую модель месторождения (рис. 3).

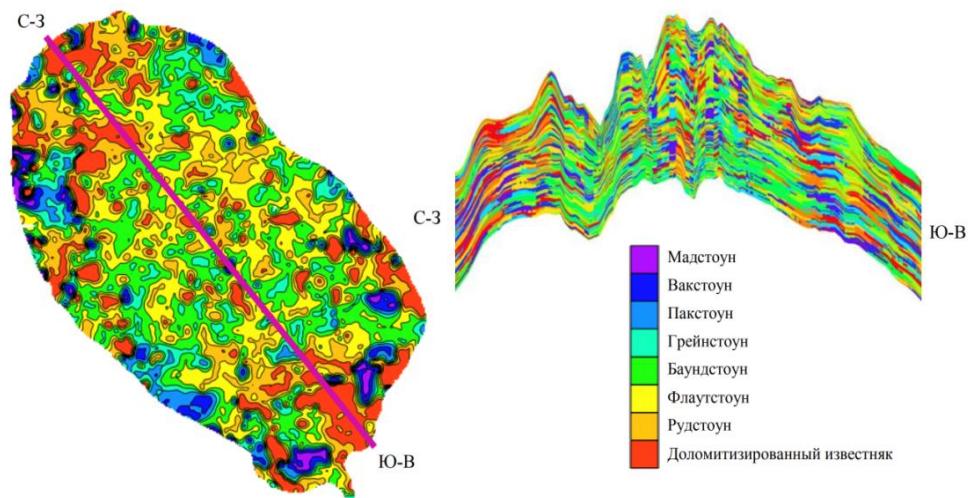


Рис. 3. Распределение литологических типов пород по данным машинного обучения [3]

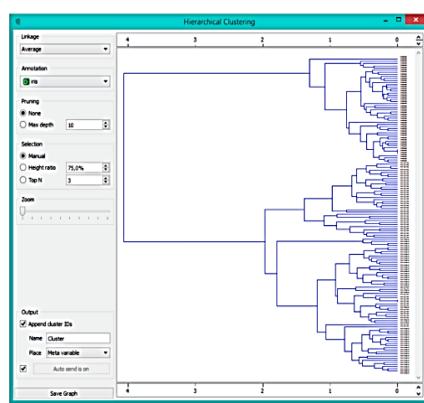
3. Практическая реализация в среде Orange Data Mining: кейс классификации лиофаций

Предлагаем рассмотреть применение платформы машинного обучения Orange для решения задачи классификации лиофаций в условиях ограниченного количества эталонных данных (рис. 4). Платформа Orange представляет собой визуальную среду для анализа данных и машинного

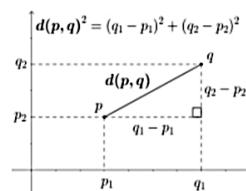
обучения, что делает ее чрезвычайно удобной для геологов и геофизиков, не являющихся экспертами в программировании [9].

Кластеризация – разделение экземпляров на отдельные группы на основе некоторой степени сходства.

Дендрограмма – визуализация по степени подобия.



Формула вычисления Евклидового расстояния.



Пример иерархической кластеризации.

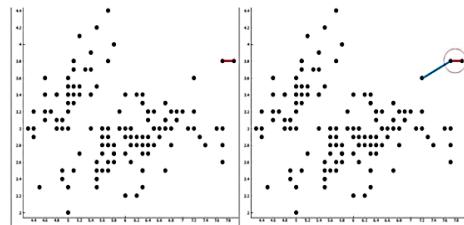


Рис. 4. Схема работы кластеризации методом ближайшего соседа

Методика и материалы

Исследование выполнено на территории одного из месторождений Западной Сибири. Целевой интервал представлен отложениями ветвящихся и меандрирующих русел, характеризующихся высокой литологической неоднородностью. В распоряжении имелись данные по 160 скважинам, однако полный комплекс исследований керна и ГИС был доступен лишь для 11 скважин («эталонные»).

Рабочий процесс был реализован следующим образом:

- загрузка таблицы данных, содержащей кривые ГИС и результаты литологической интерпретации керна;
- выбор целевой переменной (тип фации) и предикторов (кривые ГИС);
- предобработка данных (нормализация, обработка выбросов);
- настройка и обучение модели нейронной сети;
- оценка качества модели методом перекрестной проверки;
- прогнозирование фаций для скважин без данных керна.

В результате обученная модель показала точность на тестовых подвыборках в 85–88 %. Полученные результаты стали основой для построения детальной фациальной модели и были успешно верифицированы (рис. 5).

Этот пример демонстрирует, что использование визуальных средств машинного обучения предоставляет возможность эффективно решать практические задачи даже при малом объеме эталонных данных.

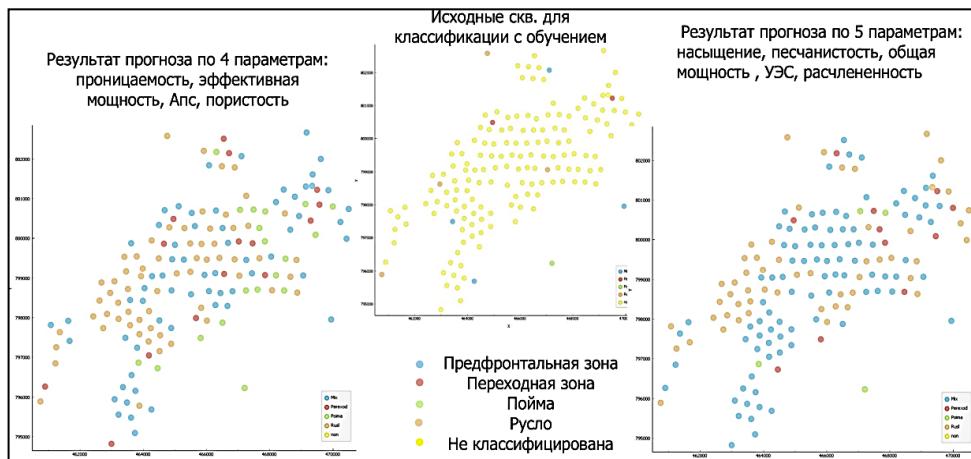


Рис. 5. Визуализация кластеризации «до» и «после» обучения на «эталонных» скважинах

Выводы

Проведенный анализ показал, что применение методов машинного обучения в нефтегазовой геологии и геофизике переживает этап активного внедрения в промышленные процессы. Нейросетевые технологии успешно решают задачи от первичной обработки данных сейсмических работ до комплексного прогнозирования свойств коллекторов, обеспечивая существенный экономический эффект за счет повышения точности и скорости интерпретации.

Платформы с визуальным программированием, а также интегрированные в профильное программное обеспечение нейронные сети играют ключевую роль в демократизации доступа к этим технологиям, позволяя специалистам-геологам активно использовать машинное обучение в своих исследованиях.

Перспективы развития направления связаны с созданием гибридных физико-статистических моделей, объединяющих детерминированные знания о процессах с возможностями машинного обучения, а также с активным использованием технологий глубокого обучения для решения наиболее сложных задач интерпретации геолого-геофизических данных

Список источников

1. Василёнок, Е. А. Классификация минеральных компонентов гранитоидов методами цифровой петрографии и машинного обучения / Е. А. Василёнок. – Текст : непосредственный // Журнал Белорусского государственного университета. География. Геология. – 2020. – № 1. – С. 75–85.
2. Королёв, В. А. Цифровизация и искусственный интеллект в инженерной геологии / В. А. Королёв. – Текст : непосредственный // Новые идеи и теоретические аспекты инженерной геологии : труды Международной научной конференции, Москва, 04 февраля 2021 г. – Москва : Сам Полиграфист, 2021. – С. 207–214.

3. Потехин, Д. В. Применение технологии машинного обучения при моделировании распределения литотипов на пермокарбоновой залежи нефти Усинского месторождения / Д. В. Потехин, С. В. Галкин. – DOI: 10.31897/PMI.2022.101. – Текст : непосредственный // Записки Горного института. – 2023. – Т. 259. – С. 41–51.
4. Старцев, В. А. Анализ опыта применения методов машинного обучения при бурении нефтяных и газовых скважин / В. А. Старцев, Г. В. Буслаев, А. В. Коноплянников. – DOI 10.33285/0130-3872-2023 -9(369)-15-24. – Текст : непосредственный // Строительство нефтяных и газовых скважин на суше и на море. – 2023. – № 9(369). – С. 15–24.
5. Alkroosh, I. S. Regressive approach for predicting bearing capacity of bored piles from cone penetration test data / I. S. Alkroosh, M. Bahadori, H. Nikraz, A. Bahadori. – DOI 10.1016/j.jrmge.2015.06.011. – Text : direct // Journal of Rock Mechanics and Geotechnical Engineering. – 2015. – Vol. 7. – Issue 5. – P. 584–592.
6. Machine learning technique for the prediction of shear wave velocity using petrophysical logs / M. Anemangely, A. Ramezanzadeh, H. Amiri, S.-A. Hosseinpour. – DOI 10.1016/j.petrol.2018.11.032. – Text : direct // Journal of Petroleum Science and Engineering, 2019. – Vol. 174. – P. 306–327.
7. Orange: Data Mining Toolbox in Python / J. Demšar, T. Curk, A. Erjavec [et al.]. – Text : direct // Journal of Machine Learning Research. – 2013. – Vol. 14. – P. 2349–2353.
8. Seismic fault detection using convolutional neural networks trained on synthetic Poststacked Amplitude Maps / A. Pochet, P. H. Diniz, H. Lopes, M. Gattass. – Text : direct // IEEE Geoscience and Remote Sensing Letters, 2018. – Vol. 16, Issue 3. – P. 352–356.
9. Deep learning method for lithology identification from borehole images / P. Y. Zhang, J. M. Sun, Y. J. Jiang, J. S. Gao. – DOI: 10.3997/2214-4609.201700945. – Text : direct // 79th EAGE Conference and Exhibition, 2017. – European Association of Geoscientists & Engineers, 2017. – Vol. 2017, Issue 1. – P. 1–5.

References

1. Vasilyonok, E. A. (2020). Klassifikaciya mineral'nyh komponentov granitoidov metodami cifrovoj petrografii i mashinnogo obucheniya. Zhurnal Belorusskogo gosudarstvennogo universiteta. Geografiya. Geologiya, (1), pp. 75-85. (In Russian).
2. Korolyov, V. A. (2021). Cifrovizaciya i iskusstvennyj intellekt v inzhenernoj geologii. Novye idei i teoretycheskie aspekty inzhenernoj geologii: trudy Mezhdunarodnoj nauchnoj konferencii. Moscow, Sam Poligrafist Publ., pp. 207-214. (In Russian).
3. Potekhin, D. V. & Galkin, S. V. (2023). Primenenie tekhnologii mashinnogo obucheniya pri modelirovaniyu raspredeleniya litotipov na permokarbonovoj zalezhi nefti Usinskogo mestorozhdeniya. Journal of Mining Institute, (259), pp. 41-51. (In Russian). DOI: 10.31897/PMI.2022.101
4. Startsev, V. A. Buslaev, G. V. & Konoplyannikov, A. V. (2023). Analysis of the experience of machine learning methods application when drilling oil and gas wells. Construction of oil and gas wells on land and sea, 9(369), pp.15-24. (In Russian). DOI: 10.33285/0130-3872-2023-9(369)-15-24
5. Alkroosh, I. S., Bahadori, M., Nikraz, H., & Bahadori, A. (2015). Regressive approach for predicting bearing capacity of bored piles from cone penetration test data. Journal of Rock Mechanics and Geotechnical Engineering, 7(5), pp. 584-592. (In English). DOI:10.1016/j.jrmge.2015.06.011

6. Anemangely, M., Ramezanzadeh, A., Amiri, H., & Hoseinpour S.-A. (2019). Machine learning technique for the prediction of shear wave velocity using petrophysical logs. *Journal of Petroleum Science and Engineering*, (174), pp. 306-327. (In English). DOI: 10.1016/j.petrol.2018.11.032
7. Demšar, J., Curk, T., Erjavec, A., Gorup, Č., Hočvar, T., Milutinović, M., & Zupan, B. (2013). Orange: data mining toolbox in Python. *Journal of machine Learning research*, 14(1), pp. 2349-2353. (In English).
8. Pochet, A., Diniz, P. H., Lopes, H., & Gattass, M. (2018). Seismic fault detection using convolutional neural networks trained on synthetic poststacked amplitude maps. *IEEE Geoscience and Remote Sensing Letters*, 16(3), pp. 352-356. (In English).
9. Zhang, P. Y., Sun, J. M., Jiang, Y. J., & Gao, J. S. (2017). Deep learning method for lithology identification from borehole images. In 79th EAGE Conference and Exhibition 2017. European Association of Geoscientists & Engineers. (1), pp. 1-5. (In English). DOI: 10.3997/2214-4609.201700945

Информация об авторах / Information about the authors

Медведев Николай Родионович,
аспирант кафедры геологии месторождений нефти и газа, Тюменский индустриальный университет,
г. Тюмень, medvedevnr@gmail.com

Бембель Сергей Робертович,
доктор геолого-минералогических наук,
профессор кафедры геологии месторождений нефти и газа, Тюменский индустриальный университет,
г. Тюмень

Савина Марина Егоровна,
старший преподаватель кафедры геологии месторождений нефти и газа,
Тюменский индустриальный университет, г. Тюмень

Nikolay R., Medvedev, Graduate Student at the Department of Geology of Oil and Gas Fields, Industrial University of Tyumen, medvedevnr@gmail.com

Sergey R. Bembel, Doctor of Geological-Mineralogical Sciences, Professor at the Department of Geology of Oil and Gas Fields, Industrial University of Tyumen

Marina E. Savina, Senior Lecturer at the Department of Geology of Oil and Gas Fields, Industrial University of Tyumen

*Поступила в редакцию / Received 25.09.2025
 Поступила после рецензирования / Revised 01.11.2025
 Принята к публикации / Accepted 05.11.2025*