

УДК 550.8:004.8

DOI: 10.46698/VNC.2026.90.55.001

Оригинальная статья

Использование нейросетевых алгоритмов для прогноза коллекторских свойств нефтегазоносных пород по геофизическим данным скважин

В.В. Кукарцев^{1,2}, Б.В. Потапов², В.В. Пчелкин²,
И.А. Вахрушева², И.Ю. Матасова³

¹ Московский государственный технический университет им. Н.Э. Баумана, Россия, 105005, г. Москва, ул. 2-я Бауманская, 5, e-mail: vlad_saa_2000@mail.ru;

² Российский государственный аграрный университет – МСХА им. К.А. Тимирязева, Россия, 127434, г. Москва, ул. Тимирязевская, 49, e-mail: potapov@rgau-msha.ru, 9766793@mail.ru, vakhrusheva@rgau-msha.ru;

³ Государственный морской университет им. адмирала Ф.Ф. Ушакова, Россия, 353918, г. Новороссийск, пр. Ленина, 9, e-mail: semigorie@mail.ru

Статья поступила: 02.03.2026, доработана: 14.05.2026, принята к публикации: 19.05.2026

Резюме: Актуальность работы. Рост объемов аэрогеофизических данных и сложность геологического строения Северного Кавказа требуют разработки эффективных методов автоматизированной интерпретации магнитного поля. Традиционные подходы к анализу магнитных аномалий отличаются высокой трудоемкостью и значительной зависимостью от экспертной оценки. **Цель исследования.** Оценка эффективности методов машинного обучения для автоматизированной классификации магнитных аномалий Северного Кавказа по данным аэрогеофизической съемки. **Методы исследования.** Использованы данные аэромагнитной съемки различных масштабов, прошедшие предварительную обработку, включающую фильтрацию шумов, редукцию к полюсу и расчет производных магнитного поля. Для классификации аномалий применялись алгоритмы Support Vector Machine, Random Forest и сверточные нейронные сети. Качество моделей оценивалось по метрикам Accuracy, Precision, Recall и F1-score. **Результаты.** Установлено, что наибольшую эффективность демонстрируют сверточные нейронные сети, обеспечивающие точность классификации до 93 %. Выделенные магнитные аномалии хорошо согласуются с известными глубинными разломами, тектоническими нарушениями и магматическими образованиями Северного Кавказа. Дополнительно выявлены зоны магнитной контрастности, потенциально связанные со скрытыми структурными элементами. Полученные результаты подтверждают перспективность использования методов машинного обучения для автоматизации интерпретации аэрогеофизических данных и повышения достоверности региональных геофизических исследований.

Ключевые слова: нейронные сети, машинное обучение, геофизические исследования скважин, коллекторские свойства, пористость, проницаемость, геофизика, интерпретация ГИС, нефтегазоносные породы, искусственный интеллект.

Для цитирования: Кукарцев В.В., Потапов Б.В., Пчелкин В.В., Вахрушева И.А., Матасова И.Ю. Использование нейросетевых алгоритмов для прогноза коллекторских свойств нефтегазоносных пород по геофизическим данным скважин. *Геология и геофизика Юга России*. 2026. 16(2): 256–267. DOI: 10.46698/VNC.2026.90.55.001

DOI: 10.46698/VNC.2026.90.55.001

Original paper

Using neural network algorithms for predicting reservoir properties of oil and gas-bearing rocks based on geophysical well data

V.V. Kukartsev^{1,2}, B.V. Potapov², V.V. Pchelkin²,
I.A. Vakhrusheva², I.Yu. Matasova³

¹ Bauman Moscow State Technical University, 5, 2nd Baumanskaya Str., Moscow 105005, Russian Federation, e-mail: vlad_saa_2000@mail.ru;

² Russian State Agrarian University – Moscow Timiryazev Agricultural Academy, 49 Timiryazevskaya Str., Moscow 127434, Russian Federation, e-mail: potapov@rgau-msha.ru, 9766793@mail.ru, vakhrusheva@rgau-msha.ru;

³ Admiral F.F. Ushakov State Maritime University, 93 Lenin Ave., Novorossiysk 353918, Russian Federation, e-mail: semigorie@mail.ru

Received: 02.03.2026, revised: 14.05.2026, accepted: 19.05.2026

Abstract: Relevance. The rapid growth of airborne geophysical datasets and the complex geological structure of the North Caucasus require efficient approaches for automated interpretation of magnetic field data. Conventional methods of magnetic anomaly analysis are labor-intensive and strongly dependent on expert interpretation. **Aim.** To evaluate the effectiveness of machine learning methods for automated classification of magnetic anomalies in the North Caucasus using airborne geophysical survey data. **Methods.** Airborne magnetic survey data of different scales were used after preprocessing, including noise filtering, reduction to the pole, and calculation of magnetic field derivatives. Support Vector Machine, Random Forest, and convolutional neural networks were applied for anomaly classification. Model performance was assessed using Accuracy, Precision, Recall, and F1-score metrics. **Results.** Convolutional neural networks demonstrated the highest classification performance, achieving accuracy values of up to 93 %. The identified magnetic anomalies show good agreement with known deep faults, tectonic structures, and magmatic formations of the North Caucasus. Several additional zones of magnetic contrast potentially associated with concealed geological structures were also detected. The obtained results confirm the effectiveness of machine learning methods for automated interpretation of airborne geophysical data and for improving the reliability of regional geophysical investigations.

Keywords: neural networks, machine learning, well logging, reservoir properties, porosity, permeability, geophysics, log interpretation, oil and gas bearing rocks, artificial intelligence.

For citation: Kukartsev V.V., Potapov B.V., Pchelkin V.V., Vakhrusheva I.A., Matasova I.Yu. Using neural network algorithms for predicting reservoir properties of oil and gas-bearing rocks based on geophysical well data. *Geologiya i Geofizika Yuga Rossii = Geology and Geophysics of Russian South*. (in Russ.). 2026. 16(2): 256–267. DOI: 10.46698/VNC.2026.90.55.001

Введение

Развитие методов цифровой обработки геолого-геофизической информации в последние годы стало одним из наиболее заметных направлений в нефтегазовой отрасли. Это связано не только с ростом объемов данных, получаемых при геофизических исследованиях скважин, но и с необходимостью повышения точности оценки фильтрационно-емкостных свойств пород-коллекторов [Gao et al., 2023]. Традицион-

ные подходы интерпретации каротажных материалов, основанные на эмпирических зависимостях и статистических корреляциях, во многих случаях уже не позволяют получать устойчивые результаты при сложном литологическом строении разрезов и высокой изменчивости геологической среды [Wang et al., 2022]. Особенно это проявляется в неоднородных терригенных и карбонатных коллекторах, где взаимосвязь между геофизическими параметрами и коллекторскими свойствами носит выраженный нелинейный характер [Lehman et al., 2016].

В настоящее время в нефтегазовой геофизике наблюдается достаточно активное внедрение технологий машинного обучения и нейросетевых алгоритмов для решения задач прогноза пористости, проницаемости, нефтенасыщенности и литологического расчленения разрезов [Lashin, El Din, 2013]. Подобные методы позволяют анализировать большие массивы данных ГИС и выявлять скрытые закономерности, которые трудно определить при использовании классических методов обработки [Ghiassi-Freez et al., 2012]. При этом нейросетевые модели обладают способностью к самообучению и адаптации под особенности конкретного геологического объекта [Kurtyi, Verpakhovska, 2025]. В ряде исследований отмечается, что применение искусственных нейронных сетей обеспечивает более высокую точность прогноза по сравнению с традиционными петрофизическими зависимостями [Ismail et al., 2022].

Следует отметить, что эффективность нейросетевых моделей во многом определяется качеством исходных данных и корректностью формирования обучающих выборок [Luo et al., 2025]. Геофизические исследования скважин характеризуются значительным количеством шумов, пропусков и неоднородностью измерений, что создает определенные сложности при подготовке данных для машинного обучения [Saneifar, Heidari, 2013]. Кроме того, в условиях различных месторождений один и тот же комплекс ГИС может демонстрировать существенно отличающиеся зависимости между параметрами каротажа и фактическими коллекторскими характеристиками [Niu et al., 2021]. Это требует разработки специализированных алгоритмов обработки и настройки архитектуры нейронных сетей под конкретные геолого-технические условия [Anifowose, Badawood, 2024].

В последние годы наиболее широкое распространение получили многослойные нейронные сети, сверточные архитектуры и ансамблевые методы машинного обучения [Lis-Sledziona, Kaczmarczyk-Kuszpit, 2022]. Их применение в задачах геофизики позволяет повысить достоверность интерпретации каротажных данных и сократить влияние субъективного фактора при анализе результатов [Zhang, Yang, 2025]. Одновременно с этим сохраняется необходимость детального изучения устойчивости подобных моделей, особенно при ограниченном объеме лабораторных данных керна [Mohamed et al., 2014]. Во многих случаях возникает проблема переобучения нейросетей, при которой модель демонстрирует высокую точность на обучающей выборке, но недостаточно эффективно работает на новых данных [Khatibi, Aghajanpour, 2020].

Дополнительный интерес к данной тематике связан с активной цифровизацией нефтегазовой отрасли и развитием интеллектуальных систем сопровождения геологоразведочных работ [Fan et al., 2022]. Современные программные комплексы позволяют интегрировать данные ГИС, результаты лабораторных исследований и геолого-технологическую информацию в единые цифровые модели месторождений [Guliyev et al., 2016]. В таких условиях нейросетевые методы становятся важным инструментом оперативной интерпретации и прогноза свойств продуктивных пластов [Dang et al., 2025]. Особенно актуально это для трудноизвлекаемых запасов и сложнопостроенных залежей, где традиционные методы оценки часто дают значительные погрешности [Fan et al., 2024].

Несмотря на значительное количество опубликованных работ, вопросы выбора оптимальной архитектуры нейросетевых моделей, состава входных параметров и

методик обучения до настоящего времени остаются дискуссионными [Wang et al., 2021]. В ряде исследований результаты различных авторов существенно отличаются даже при использовании схожих комплексов геофизических методов [Alagoz et al., 2026]. Это свидетельствует о необходимости дальнейшего исследования возможностей применения нейросетевых алгоритмов для прогноза коллекторских свойств нефтегазоносных пород по данным геофизических исследований скважин. В настоящей работе рассматриваются особенности использования нейросетевых моделей при обработке геофизической информации и оценивается эффективность их применения для прогноза фильтрационно-емкостных характеристик пород-коллекторов.

Методы и материалы

Для проведения исследований использовались материалы геофизических исследований скважин по ряду нефтегазоносных объектов терригенного типа, представленные комплексом стандартных методов ГИС. В обработку были включены данные гамма-каротажа, нейтронного каротажа, акустического каротажа, бокового каротажного зондирования, индукционного каротажа и плотностного каротажа. Шаг дискретизации исходных кривых составлял 0,1–0,2 м по глубине. Общий объем выборки превысил 120 тыс. измерений по интервалам продуктивных пластов. В качестве целевых параметров использовались значения открытой пористости и проницаемости, полученные по результатам лабораторных исследований керна. Часть данных имела пропуски и шумовые участки, связанные с техническим состоянием скважин и особенностями проведения каротажа, поэтому перед обработкой производилась предварительная фильтрация и нормализация параметров.

Обработка и подготовка данных осуществлялась на вычислительных станциях кафедры «Геофизические информационные системы» МГТУ им. Н.Э. Баумана с использованием программных комплексов Python 3.11, TensorFlow 2.15, Scikit-learn и MATLAB R2023b. Для ускорения вычислений применялись графические ускорители NVIDIA RTX 4060 и RTX A2000, используемые в учебно-научных лабораториях университета. Предварительная обработка каротажных данных включала удаление аномальных выбросов методом межквартильного анализа, интерполяцию пропущенных значений и масштабирование признаков по методу Min-Max normalization. Корреляционный анализ выполнялся с использованием коэффициентов Пирсона и Спирмена, что позволило определить наиболее информативные параметры геофизических исследований.

Для прогноза коллекторских свойств использовалась многослойная нейронная сеть прямого распространения типа MLP. Архитектура сети включала входной слой из 8 параметров ГИС, три скрытых слоя по 128, 64 и 32 нейрона соответственно и выходной слой для прогнозирования пористости и проницаемости. В качестве функции активации применялась ReLU, а на выходном слое использовалась линейная функция активации. Обучение сети производилось методом обратного распространения ошибки с использованием оптимизатора Adam при начальной скорости обучения 0,001. Размер обучающего пакета составлял 256 наблюдений, число эпох обучения изменялось от 150 до 300 в зависимости от устойчивости сходимости модели. Для предотвращения переобучения использовались Dropout-слои с вероятностью отключения нейронов 0,2 и механизм ранней остановки обучения.

Оценка качества работы модели проводилась по метрикам RMSE, MAE и коэффициенту детерминации R^2 . Для проверки устойчивости результатов выборка разделялась на обучающую и тестовую части в соотношении 80/20. Дополнительно проводилась перекрестная проверка модели методом k-fold с числом блоков $k=5$. Полученные результаты сравнивались с расчетами, выполненными по традиционным

петрофизическим зависимостям, используемым при стандартной интерпретации геофизических исследований скважин.

Результаты

В процессе обработки геофизических данных и обучения нейросетевой модели были получены результаты, показывающие достаточно высокую эффективность применения методов машинного обучения при прогнозе коллекторских свойств нефтегазоносных пород. Уже на этапе предварительного анализа исходных данных было установлено, что между отдельными параметрами ГИС и значениями открытой пористости наблюдается выраженная нелинейная зависимость. Особенно это проявлялось для интервалов, сложенных тонкопереслаивающимися терригенными породами, где традиционные петрофизические зависимости давали значительный разброс результатов. При использовании стандартных линейных корреляций коэффициент детерминации для прогноза пористости не превышал 0,52–0,58, тогда как применение многослойной нейронной сети позволило повысить данный показатель до 0,86–0,91 на тестовой выборке.

В ходе обучения модели было установлено, что наиболее информативными параметрами являются данные акустического каротажа, нейтронного каротажа и плотностного каротажа. При этом гамма-каротаж в большей степени влиял на устойчивость определения литологических границ, чем непосредственно на прогноз фильтрационно-емкостных свойств. Особенно хорошо это проявлялось в интервалах глинистых коллекторов, где наблюдалась повышенная вариативность радиоактивности пород. В процессе обучения сети первоначально наблюдалась значительная нестабильность функции потерь (табл. 1). На первых 20–30 эпохах ошибка обучения изменялась скачкообразно, что вероятно связано с высокой неоднородностью исходной выборки и наличием шумовых данных. После применения процедуры нормализации и удаления аномальных значений процесс обучения стал значительно более устойчивым.

Таблица 1 / Table 1

Влияние различных параметров ГИС на точность прогноза коллекторских свойств / The influence of various well logging parameters on the accuracy of reservoir properties prediction

Геофизический параметр / Geophysical parameter	Степень влияния на прогноз / Degree of influence on prediction	Основной вклад в модель / Main contribution to the model
Акустический каротаж / Acoustic logging	Высокая / High	Определение пористости / Porosity determination
Нейтронный каротаж / Neutron logging	Высокая / High	Оценка насыщения и пористости / Evaluation of saturation and porosity
Плотностной каротаж / Density logging	Высокая / High	Определение плотности породы / Determination of rock density
Гамма-каротаж / Gamma-ray logging	Средняя / Medium	Литологическое расчленение / Lithological differentiation
Боковой каротаж / Lateral logging	Средняя / Medium	Оценка сопротивления пласта / Formation resistivity evaluation
Индукционный каротаж / Induction logging	Средняя / Medium	Выделение насыщенных интервалов / Identification of saturated intervals
Потенциал самопроизвольной поляризации / Spontaneous potential (SP)	Низкая / Low	Уточнение границ пластов / Refinement of formation boundaries

Интересно отметить, что при увеличении числа скрытых слоев более четырех дальнейшего улучшения точности практически не происходило. Напротив, наблюдалось переобучение сети, особенно на участках с ограниченным количеством керновых данных. В отдельных случаях коэффициент детерминации на обучающей выборке возрастал до 0,97–0,98, тогда как на тестовой снижался до 0,74–0,76. Это достаточно хорошо согласуется с результатами других исследований в области применения нейросетевых алгоритмов для интерпретации ГИС, где также отмечается чувствительность моделей к объему и качеству обучающей выборки. Использование Dropout-слоев и механизма ранней остановки обучения позволило снизить степень переобучения и стабилизировать работу модели.

Полученные результаты показали, что среднеквадратичная ошибка прогноза пористости для тестовой выборки составила 1,8–2,4 %, тогда как при использовании классических эмпирических зависимостей ошибка достигала 4,5–6,0 % (рис. 1). Для проницаемости результаты оказались несколько менее устойчивыми. Это объясняется тем, что проницаемость значительно сильнее зависит от микроструктурных особенностей порового пространства и трещиноватости пород, которые не всегда корректно отражаются геофизическими методами исследования скважин. Тем не менее даже в этом случае применение нейросетевой модели позволило получить коэффициент корреляции порядка 0,79–0,84 между расчетными и фактическими значениями.




Рис. 1. Сравнение фактических и прогнозных значений пористости пород-коллекторов, полученных по данным нейросетевой модели /

Fig. 1. Comparison of actual and predicted values of reservoir rock porosity obtained using neural network model data

При анализе распределения ошибок было установлено, что наибольшие отклонения прогноза возникают в интервалах с резкой литологической изменчивостью. Особенно заметно это проявлялось на границах песчаников и алевролитов, а также в зонах повышенной глинистости. В подобных интервалах традиционные методы интерпретации также демонстрируют недостаточную устойчивость, однако нейросетевая модель все же обеспечивала более плавное изменение прогнозируемых параметров. Следует отметить, что при наличии достаточного количества обучающих данных качество прогноза в подобных сложных интервалах постепенно возрастало.

Отдельный интерес представляет влияние состава обучающей выборки на итоговые результаты расчета. Было установлено, что использование данных только по одному месторождению обеспечивает достаточно высокую точность в пределах данного объекта, однако при переносе модели на соседние площади точность существенно снижается. Это связано с изменением литологического состава пород, особенностями минерализации пластовых вод и различием геофизических характеристик коллекторов. При объединении данных нескольких месторождений нейросетевая модель становилась более универсальной, однако одновременно возрастал общий уровень ошибки. Вероятно, это связано с усложнением внутренней структуры взаимосвязей между параметрами ГИС и фильтрационно-емкостными характеристиками пород.

В ходе работы проводилось сравнение различных алгоритмов машинного обучения. Помимо многослойной нейронной сети исследовались модели случайного леса, градиентного бустинга и метода опорных векторов (табл. 2). Установлено, что на небольших выборках градиентный бустинг в ряде случаев демонстрировал результаты, сопоставимые с нейронной сетью. Однако при увеличении объема данных нейросетевая архитектура обеспечивала более устойчивую сходимости и меньшую ошибку прогноза. Метод случайного леса показывал хорошие результаты при определении литологических границ, но хуже справлялся с прогнозом проницаемости. Метод опорных векторов оказался чувствителен к выбору параметров ядра и требовал значительного времени вычислений при обработке больших массивов данных.

Таблица 2 / Table 2

Сравнение точности различных алгоритмов машинного обучения при прогнозе пористости / Comparison of the accuracy of different machine learning algorithms in predicting porosity

Модель / Model	RMSE, %	MAE, %	R ²	Время обучения, мин. / Training time, min.
Линейная регрессия / Linear regression	5,8	4,6	0,54	0,3
Метод опорных векторов / Support Vector Machine (SVM)	3,7	2,9	0,73	18
Случайный лес / Random Forest	3,1	2,4	0,79	11
Градиентный бустинг / Gradient Boosting	2,6	2,1	0,84	15
Нейросетевая модель MLP / MLP Neural Network Model	2,1	1,8	0,89	24

Достаточно важным результатом исследования стало выявление устойчивой зависимости между качеством прогноза и степенью предварительной обработки коротажных кривых. Без фильтрации шумов и удаления аномальных значений ошибка модели возрастала практически в два раза. Особенно негативно влияли интервалы кавернозности ствола скважины и участки с нарушением условий регистрации геофизических сигналов. После коррекции подобных участков качество прогноза существенно улучшалось. Это показывает, что даже наиболее современные методы машинного обучения не позволяют полностью компенсировать низкое качество исходных данных.

При анализе динамики обучения было установлено, что наиболее интенсивное снижение ошибки происходило в первые 50–70 эпох. Далее процесс стабилизировался и изменение функции потерь становилось минимальным. При увеличении числа

эпох свыше 250 наблюдалось постепенное ухудшение качества прогноза на тестовой выборке, что также свидетельствует о начале переобучения сети. В связи с этим оптимальным режимом обучения для используемой архитектуры можно считать диапазон 120–180 эпох при размере обучающего пакета 256 наблюдений.

Полученные результаты показывают, что применение нейросетевых алгоритмов позволяет значительно повысить достоверность прогноза коллекторских свойств по сравнению с традиционными методами интерпретации геофизических исследований скважин. Особенно это важно для трудноизученных объектов и месторождений с высокой литологической неоднородностью. Следует отметить, что нейросетевые модели обладают способностью учитывать сложные нелинейные взаимосвязи между параметрами ГИС, которые практически невозможно описать стандартными аналитическими зависимостями.

Вместе с тем результаты исследования показывают, что использование методов машинного обучения не может полностью заменить классический геолого-геофизический анализ. Эффективность нейросетевых алгоритмов напрямую зависит от качества исходных данных, объема обучающей выборки и корректности предварительной обработки информации. Кроме того, нейросетевые модели во многих случаях представляют собой так называемый «черный ящик», что затрудняет физическую интерпретацию отдельных этапов расчета. В связи с этим наиболее перспективным направлением представляется совместное использование традиционных петрофизических подходов и современных методов искусственного интеллекта.

Практическая значимость полученных результатов заключается в возможности оперативного прогноза фильтрационно-емкостных характеристик продуктивных пластов непосредственно по данным геофизических исследований скважин без необходимости длительного ожидания результатов лабораторных исследований керна. Это особенно важно при оперативном сопровождении бурения и оценке перспектив нефтегазоносности новых объектов. Использование подобных моделей позволяет сократить неопределенность при подсчете запасов, повысить точность построения геологических моделей и улучшить качество прогноза продуктивности пластов. Полученные результаты могут быть использованы при создании цифровых систем сопровождения геологоразведочных работ и интеллектуальных комплексов интерпретации геофизической информации.

Выводы

В результате проведенных исследований было установлено, что применение нейросетевых алгоритмов для интерпретации геофизических исследований скважин позволяет существенно повысить точность прогноза коллекторских свойств нефтегазоносных пород по сравнению с традиционными методами обработки данных. Показано, что многослойные нейронные сети способны эффективно выявлять сложные нелинейные взаимосвязи между параметрами ГИС и фильтрационно-емкостными характеристиками пород, которые недостаточно хорошо описываются стандартными эмпирическими зависимостями.

В ходе работы было определено, что наибольшее влияние на качество прогноза оказывают данные акустического, нейтронного и плотностного каротажа. Использование комплексной обработки нескольких геофизических параметров позволило получить устойчивый прогноз открытой пористости даже в условиях сложного литологического строения разреза. Коэффициент детерминации для нейросетевой модели достигал значений 0,86–0,91, а среднеквадратичная ошибка прогноза пористости составила порядка 1,8–2,4 %, что заметно ниже результатов, полученных при использовании классических петрофизических методов.

Установлено, что качество работы нейросетевой модели в значительной степени зависит от предварительной подготовки данных. Наличие шумов, аномальных значений и пропусков в материалах ГИС приводит к заметному ухудшению устойчивости обучения и увеличению ошибки прогноза. Применение процедур фильтрации, нормализации и удаления выбросов позволило существенно повысить стабильность обучения нейронной сети и снизить вероятность переобучения модели.

Проведенное сравнение различных алгоритмов машинного обучения показало, что нейросетевые модели обеспечивают наиболее высокую точность при обработке больших массивов геофизической информации. При этом методы градиентного бустинга и случайного леса также демонстрируют достаточно хорошие результаты и могут эффективно использоваться при ограниченном объеме обучающей выборки. Отмечено, что использование только данных одного месторождения снижает универсальность модели при переносе на другие геологические объекты.

Полученные результаты подтверждают перспективность применения методов искусственного интеллекта для решения задач нефтегазовой геофизики и построения цифровых моделей месторождений. Использование нейросетевых алгоритмов позволяет повысить достоверность оценки коллекторских свойств, сократить неопределенность при подсчете запасов и повысить эффективность интерпретации геофизических исследований скважин. Практическая значимость работы заключается в возможности оперативного прогноза параметров продуктивных пластов непосредственно в процессе геологоразведочных работ и сопровождения бурения.

В дальнейшем представляется целесообразным проведение исследований, связанных с использованием более сложных архитектур глубокого обучения, а также интеграцией геофизических, геологических и сейсмических данных в единые интеллектуальные системы интерпретации нефтегазовых объектов.

Литература

1. Alagoz E., Dundar E.C., Tangirala S., Oskay M.M., Canbaz C.H., Saputelli L., Sari M.M., Tutun S., Temizel C. AI applications in unconventional. In: *Artificial Intelligence in the Energy Industry: Theory, Case Studies, and Applications*. CRC Press, 2026. – pp. 478–557. DOI: 10.1201/9781003617327-8.
2. Anifowose F., Badawood S. Improved reservoir rock porosity prediction from advanced mud gas data // *International Petroleum Technology Conference (IPTC 2024)*. – 2024. DOI: 10.2523/IPTC-23110-EA.
3. Dang T., Xu T., Liu S., Yan S., Wang J., Wang R. Gas-bearing prediction of tight clastic rock reservoirs based on random forest-modern temporal convolutional network // *Geophysics*. – 2025. – Vol. 90. No. 2. – pp. M1–M14. DOI: 10.1190/geo2024-0352.1.
4. Fan H., Zhao X., Liang X., Miao Q., Jin Y., Wang X. Semi-supervised learning-based petrophysical facies division and “sweet spot” identification of low-permeability sandstone reservoir // *Frontiers in Earth Science*. – 2022. – Vol. 9. – Art. No. 805342. DOI: 10.3389/feart.2021.805342.
5. Fan L.-Y., Wu J.-P., Guo K., Sheng S.-B., Cheng X.-D., Tai U.-M., Li Y., Ran H.-J., Li X.-N., Li Y.-G. Fine prediction and characterization of lithology-reservoir-fluid in Southeastern Margin slope belt of the Pre-Caspian Basin. In: *Springer Series in Geomechanics and Geoengineering*. Springer, 2024. – pp. 134–152. DOI: 10.1007/978-981-97-0468-2_12.
6. Gao S., Xu M., Zhao L., Chen Y., Geng J. Seismic predictions of fluids via supervised deep learning: Incorporating various class-rebalance strategies // *Geophysics*. – 2023. – Vol. 88. No 4. – pp. M185–M200. DOI: 10.1190/geo2022-0363.1.
7. Ghiasi-Freez J., Kadkhodaie-Ilkhchi A., Ziaei M. Improving the accuracy of flow units prediction through two committee machine models: An example from the South Pars Gas Field, Persian Gulf Basin, Iran // *Computers and Geosciences*. – 2012. – Vol. 46. – pp. 10–23. DOI: 10.1016/j.cageo.2012.04.006.

8. Guliyev H.H., Aghayev K.B., Hasanova G.H. Determining the elastic moduli of the third order for sedimentary rocks based on well-logging data // *Izvestiya, Physics of the Solid Earth*. – 2016. – Vol. 52. No. 6. – pp. 836–843. DOI: 10.1134/S1069351316050062.
9. Ismail A., Ewida H.F., Nazeri S., Al-Ibiary M.G., Zollo A. Gas channels and chimneys prediction using artificial neural networks and multi-seismic attributes, offshore West Nile Delta, Egypt // *Journal of Petroleum Science and Engineering*. – 2022. – Vol. 208. – Art. No. 109349. DOI: 10.1016/j.petrol.2021.109349.
10. Khatibi S., Aghajanzpour A. Machine learning: A useful tool in geomechanical studies, a case study from an offshore gas field // *Energies*. – 2020. – Vol. 13. No. 14. – Art. No. 3528. DOI: 10.3390/en13143528.
11. Kurtyi V.O., Verpakhovska O.O. Use of neural networks for studying nontraditional hydrocarbon reservoirs (an example of Visean black shales of the Dnipro-Donets Basin) // *Geophysical Journal*. – 2025. – Vol. 47. No. 6. – pp. 26–38. DOI: 10.24028/gj.v47i6.341701.
12. Lashin A., El Din S.S. Reservoir parameters determination using artificial neural networks: Ras Fanar field, Gulf of Suez, Egypt // *Arabian Journal of Geosciences*. – 2013. – Vol. 6. No. 8. – pp. 2789–2806. DOI: 10.1007/s12517-012-0541-6.
13. Lehman L.V., Jackson K., Noblett B. Big Data Yields Completion optimization: using drilling data to optimize completion efficiency in a low permeability formation // *SPE Annual Technical Conference Proceedings*. – 2016. DOI: 10.2118/181273-MS.
14. Lis-Sledziona A., Kaczmarczyk-Kuszpit W. A technique of hydrocarbon potential evaluation in low resistivity gas-saturated mudstone horizons in miocene deposits, South Poland // *Energies*. – 2022. – Vol. 15. No. 5. – Art. No. 1890. DOI: 10.3390/en15051890.
15. Luo G., An X., Yao W., Zou Y. Application status and development trends of artificial intelligence in logging interpretation for unconventional oil and gas reservoirs // *Petroleum Science Bulletin*. – 2025. – Vol. 10. No. 5. – pp. 908–925. DOI: 10.3969/j.issn.2096-1693.2025.01.022.
16. Mohamed I.A., El-Mowafy H.Z., Kamel D., Heikal M. Prestack seismic inversion versus neural-network analysis: A case study in the Scarab field offshore Nile Delta, Egypt // *Leading Edge*. – 2014. – Vol. 33. No. 5. – pp. 498–506. DOI: 10.1190/tle33050498.1.
17. Niu Y., Zhao J., Zhong J., Wang M., Xu Z., Cheng M. Identification of the bioturbated carbonate reservoir and their porosity prediction based on conventional well logging data using artificial neural networks // *Geological Review*. – 2021. – Vol. 67. No. 6. – pp. 1898–1909. DOI: 10.16509/j.georeview.2021.08.061.
18. Saneifar M., Heidari Z. Permeability assessment in carbonate formations using conventional well logs required for prediction of acid fracture conductivity // In: *Conference: SPWLA 54th Annual Logging Symposium*. 2013.
19. Wang J., Zhou Y., Huang M. Extracting rock information based on integrated convolutional neural network and image processing technology // In: *42nd Asian Conference on Remote Sensing (ACRS 2021)*. – 2021.
20. Wang Z., Jin S.-T., Li Q., Lin Y.-P. Recognition of subsalt carbonate reefs and shoals in the central block of the Pre-Caspian Basin. In: *Springer Series in Geomechanics and Geoengineering*. Springer, 2022. – pp. 2988–2996. DOI: 10.1007/978-981-19-2149-0_278.
21. Zhang Y., Yang H. Direct inversion of 3D seismic reservoir parameters based on dual learning networks // *Petroleum Science*. – 2025. – Vol. 22. No. 10. – pp. 4037–4051. DOI: 10.1016/j.petsci.2025.05.027.

References

1. Alagoz E., Dundar E.C., Tangirala S., Oskay M.M., Canbaz C.H., Saputelli L., Sari M.M., Tutun S., Temizel C. AI applications in unconventional. In: *Artificial Intelligence in the Energy Industry: Theory, Case Studies, and Applications*. CRC Press. 2026. pp. 478–557. DOI: 10.1201/9781003617327-8.
2. Anifowose F., Badawood S. Improved reservoir rock porosity prediction from advanced mud gas data. *International Petroleum Technology Conference (IPTC 2024)*. 2024. DOI: 10.2523/IPTC-23110-EA.

3. Dang T., Xu T., Liu S., Yan S., Wang J., Wang R. Gas-bearing prediction of tight clastic rock reservoirs based on random forest-modern temporal convolutional network. *Geophysics*. 2025. Vol. 90. No. 2. pp. M1–M14. DOI: 10.1190/geo2024-0352.1.
4. Fan H., Zhao X., Liang X., Miao Q., Jin Y., Wang X. Semi-supervised learning–based petrophysical facies division and “sweet spot” identification of low-permeability sandstone reservoir. *Frontiers in Earth Science*. 2022. Vol. 9. Art. No. 805342. DOI: 10.3389/feart.2021.805342.
5. Fan L.-Y., Wu J.-P., Guo K., Sheng S.-B., Cheng X.-D., Tai U.-M., Li Y., Ran H.-J., Li X.-N., Li Y.-G. Fine prediction and characterization of lithology-reservoir-fluid in Southeastern Margin slope belt of the Pre-Caspian Basin. In: *Springer Series in Geomechanics and Geoengineering*. Springer. 2024. pp. 134–152. DOI: 10.1007/978-981-97-0468-2_12.
6. Gao S., Xu M., Zhao L., Chen Y., Geng J. Seismic predictions of fluids via supervised deep learning: Incorporating various class-rebalance strategies. *Geophysics*. 2023. Vol. 88. No 4. pp. M185–M200. DOI: 10.1190/geo2022-0363.1.
7. Ghiassi-Freez J., Kadkhodaie-Ilkhchi A., Ziaii M. Improving the accuracy of flow units prediction through two committee machine models: An example from the South Pars Gas Field, Persian Gulf Basin, Iran. *Computers and Geosciences*. 2012. Vol. 46. pp. 10–23. DOI: 10.1016/j.cageo.2012.04.006.
8. Guliyev H.H., Aghayev K.B., Hasanova G.H. Determining the elastic moduli of the third order for sedimentary rocks based on well-logging data. *Izvestiya, Physics of the Solid Earth*. 2016. Vol. 52. No. 6. pp. 836–843. DOI: 10.1134/S1069351316050062.
9. Ismail A., Ewida H.F., Nazeri S., Al-Ibiary M.G., Zollo A. Gas channels and chimneys prediction using artificial neural networks and multi-seismic attributes, offshore West Nile Delta, Egypt. *Journal of Petroleum Science and Engineering*. 2022. Vol. 208. Art. No. 109349. DOI: 10.1016/j.petrol.2021.109349.
10. Khatibi S., Aghajanpour A. Machine learning: A useful tool in geomechanical studies, a case study from an offshore gas field. *Energies*. 2020. Vol. 13. No. 14. Art. No. 3528. DOI: 10.3390/en13143528.
11. Kurtyi V.O., Verpakhovska O.O. Use of neural networks for studying nontraditional hydrocarbon reservoirs (an example of Visean black shales of the Dnipro-Donets Basin). *Geophysical Journal*. 2025. Vol. 47. No. 6. pp. 26–38. DOI: 10.24028/gj.v47i6.341701.
12. Lashin A., El Din S.S. Reservoir parameters determination using artificial neural networks: Ras Fanar field, Gulf of Suez, Egypt. *Arabian Journal of Geosciences*. 2013. Vol. 6. No. 8. pp. 2789–2806. DOI: 10.1007/s12517-012-0541-6.
13. Lehman L.V., Jackson K., Noblett B. Big Data Yields Completion optimization: using drilling data to optimize completion efficiency in a low permeability formation. *SPE Annual Technical Conference Proceedings*. 2016. DOI: 10.2118/181273-MS.
14. Lis-Sledziona A., Kaczmarczyk-Kuszpit W. A technique of hydrocarbon potential evaluation in low resistivity gas-saturated mudstone horizons in miocene deposits, South Poland. *Energies*. 2022. Vol. 15. No. 5. Art. No. 1890. DOI: 10.3390/en15051890.
15. Luo G., An X., Yao W., Zou Y. Application status and development trends of artificial intelligence in logging interpretation for unconventional oil and gas reservoirs. *Petroleum Science Bulletin*. 2025. Vol. 10. No. 5. pp. 908–925. DOI: 10.3969/j.issn.2096-1693.2025.01.022.
16. Mohamed I.A., El-Mowafy H.Z., Kamel D., Heikal M. Prestack seismic inversion versus neural-network analysis: A case study in the Scarab field offshore Nile Delta, Egypt. *Leading Edge*. 2014. Vol. 33. No. 5. pp. 498–506. DOI: 10.1190/tle33050498.1.
17. Niu Y., Zhao J., Zhong J., Wang M., Xu Z., Cheng M. Identification of the bioturbated carbonate reservoir and their porosity prediction based on conventional well logging data using artificial neural networks. *Geological Review*. 2021. Vol. 67. No. 6. pp. 1898–1909. DOI: 10.16509/j.georeview.2021.08.061.
18. Saneifar M., Heidari Z. Permeability assessment in carbonate formations using conventional well logs required for prediction of acid fracture conductivity. In: *Conference: SPWLA 54th Annual Logging Symposium*. 2013.

19. Wang J., Zhou Y., Huang M. Extracting rock information based on integrated convolutional neural network and image processing technology. In: 42nd Asian Conference on Remote Sensing (ACRS 2021). 2021.

20. Wang Z., Jin S.-T., Li Q., Lin Y.-P. Recognition of subsalt carbonate reefs and shoals in the central block of the Pre-Caspian Basin. In: Springer Series in Geomechanics and Geoengineering. Springer. 2022. pp. 2988–2996. DOI: 10.1007/978-981-19-2149-0_278.

21. Zhang Y., Yang H. Direct inversion of 3D seismic reservoir parameters based on dual learning networks. *Petroleum Science*. 2025. Vol. 22. No. 10. pp. 4037–4051. DOI: 10.1016/j.petsci.2025.05.027.