

УДК 004.8:550.8:622.24

МРНТИ 52.47.15

DOI: [10.54859/kjogi108909](https://doi.org/10.54859/kjogi108909)

Получена: 28.03.2025.

Одобрена: 15.05.2026.

Опубликована: 30.06.2026.

Оригинальное исследование

Применение искусственного интеллекта в нефтегазовой отрасли: тренд или необходимость?

А.И. Аяганова¹, Д.Ж. Курмангалиев², А.Ш. Абилгазиева¹, Н.К. Дукесова²

¹Атырауский университет нефти и газа им. Сафу Утебаева, г. Атырау, Казахстан

²КМГ Инжиниринг, г. Астана, Казахстан

АННОТАЦИЯ

Обоснование. В последние десятилетия технологии искусственного интеллекта (далее – ИИ) стремительно внедряются в нефтегазовую отрасль, охватывая ключевые этапы геологоразведки, интерпретации геофизических данных, моделирования пластов и разработки месторождений. Современные методы анализа больших данных, машинного обучения и интеллектуальные системы управления позволяют повысить точность интерпретации геолого-геофизических и каротажных данных, снизить уровень неопределённости при принятии инженерных решений, минимизировать производственные риски и оптимизировать процессы разведки и добычи углеводородов.

Цель. В статье рассмотрены современные направления применения ИИ в нефтегазовой индустрии с акцентом на задачи автоматизированной интерпретации данных геофизических исследований скважин (далее – ГИС), классификации литологического состава пород, реконструкции каротажных кривых и цифровизации геологоразведочных процессов. Проведён анализ мирового опыта внедрения технологий ИИ в области каротажа, обработки и интерпретации геолого-геофизической информации, а также рассмотрены интегрированные программные решения и цифровые платформы ведущих международных нефтесервисных и нефтегазовых компаний.

Материалы и методы. Особое внимание уделено практическому опыту применения методов машинного обучения в ТОО «КМГ Инжиниринг» для автоматизированной классификации литологии по данным ГИС. В рамках исследования были протестированы различные алгоритмы машинного обучения, включая Logistic Regression, Random Forest, XGBoost и другие алгоритмы машинного обучения, на основе данных более 100 скважин. Рассмотрены особенности подготовки и очистки данных, формирования обучающих и тестовых выборок, а также проблемы, связанные с неполнотой, неоднородностью и низким качеством исторических геолого-геофизических данных.

Результаты. Результаты исследования показали, что применение ансамблевых методов и алгоритмов градиентного бустинга позволяет достигать высокой точности классификации литологических типов и эффективно автоматизировать процессы интерпретации каротажных данных. Наилучшие результаты были получены при использовании алгоритма Random Forest, продемонстрировавшего высокую устойчивость и качество прогнозирования в условиях реальных производственных данных. Отдельно рассмотрены вопросы интеграции обученных моделей в корпоративные информационные системы для оперативного прогнозирования литологии и поддержки принятия геолого-технических решений.

Заключение. Сделан вывод о том, что внедрение технологий искусственного интеллекта является одним из ключевых направлений цифровой трансформации нефтегазовой отрасли Казахстана. Использование ИИ позволяет повысить эффективность геологоразведочных работ, ускорить обработку и интерпретацию данных, повысить коэффициент извлечения углеводородов и снизить затраты на разработку месторождений в условиях возрастающей сложности геологического строения и ухудшения качества ресурсной базы.

Ключевые слова: искусственный интеллект, машинное обучение, нефтегазовая отрасль, геофизические исследования скважин, геофизические исследования скважин, каротаж, литология, Random Forest, XGBoost, автоматизированная интерпретация, цифровизация, геологоразведка, нейронные сети, анализ данных, классификация пород.

Как цитировать:

Аяганова А.И., Курмангалиев Д.Ж., Абилгазиева А.Ш., Дукесова Н.К. Применение искусственного интеллекта в нефтегазовой отрасли: тренд или необходимость? // Вестник нефтегазовой отрасли Казахстана. 2026. Том 8, №2. С. 59–73. DOI: [10.54859/kjogi108909](https://doi.org/10.54859/kjogi108909).

UDC 004.8:550.8:622.24

CSCSTI 52.47.15

DOI: [10.54859/kjogi108909](https://doi.org/10.54859/kjogi108909)

Received: 28.03.2025.

Accepted: 15.05.2026.

Published: 30.06.2026.

Original article

Application of Artificial Intelligence in the Oil and Gas Industry: Trend or Necessity?

Anar I. Ayaganova¹, Darkhan Zh. Kurmangaliyev², Aliya Sh. Abilgazyieva¹,
Nadezhda K. Dukessova²

¹Atyrau Oil and Gas University, Atyrau, Kazakhstan

²KMG Engineering, Astana, Kazakhstan

ABSTRACT

Background: In recent decades, artificial intelligence technologies (hereinafter – AI) have been rapidly integrated into the oil and gas industry, covering key stages of geological exploration, geophysical data interpretation, reservoir modeling, and field development. Modern methods of big data analysis, machine learning, and intelligent control systems make it possible to improve the accuracy of interpreting geological, geophysical, and well logging data, reduce uncertainty in engineering decision-making, minimize operational risks, and optimize hydrocarbon exploration and production processes.

Aim: This article examines contemporary areas of AI application in the oil and gas industry, with a particular focus on the tasks of automated interpretation of well logging data (hereinafter – WL), classification of lithological rock composition, reconstruction of logging curves, and digitalization of geological exploration processes. An analysis of global experience in implementing AI technologies in the field of well logging, processing and interpretation of geological and geophysical information is conducted, and integrated software solutions and digital platforms of leading international oilfield service and oil and gas companies are also reviewed.

Materials and Methods: Particular attention is given to the practical experience of applying machine learning methods at KMG Engineering LLP for automated lithology classification based on well logging data. Within the framework of the study, various machine learning algorithms, including Logistic Regression, Random Forest, XGBoost, and other machine learning algorithms, were tested using data from more than 100 wells. The study also considers the specifics of data preparation and cleaning, the formation of training and test datasets, as well as issues related to incompleteness, heterogeneity, and the low quality of historical geological and geophysical data.

Results: The results of the study demonstrated that the application of ensemble methods and gradient boosting algorithms makes it possible to achieve high accuracy in lithological type classification and effectively automate the interpretation of well logging data. The best results were obtained using the Random Forest algorithm, which demonstrated high robustness and predictive performance under real production data conditions. Particular attention is also given to the integration of trained models into corporate information systems for operational lithology prediction and support of geological and technical decision-making.

Conclusion: It is concluded that the implementation of artificial intelligence technologies represents one of the key directions of digital transformation in the oil and gas industry of Kazakhstan. The use of AI makes it possible to improve the efficiency of geological exploration activities, accelerate data processing and interpretation, increase hydrocarbon recovery factors, and reduce field development costs under conditions of increasing geological complexity and declining resource base quality.

Keywords: artificial intelligence; machine learning; oil and gas industry; well logging; well logging; logging; lithology; Random Forest; XGBoost; automated interpretation; digitalization; geological exploration; neural networks; data analysis; rock classification.

To cite this article:

Ayaganova AI, Kurmangaliyev DZ, Abilgazyieva AS, Dukessova NK. Application of Artificial Intelligence in the Oil and Gas Industry: Trend or Necessity? *Kazakhstan journal for oil & gas industry*. 2026;8(2):59–73. DOI: [10.54859/kjogi108909](https://doi.org/10.54859/kjogi108909).

ӨОЖ 004.8:550.8:622.24

ГТАХР 52.47.15

DOI: [10.54859/kjogi108909](https://doi.org/10.54859/kjogi108909)

Қабылданды: 28.03.2025.

Мақұлданды: 15.05.2026.

Жарияланды: 30.06.2026.

Түпнұсқа зерттеу

Мұнай-газ саласында жасанды интеллектті қолдану: тренд пе, әлде қажеттілік пе?

А.І. Аяғанова¹, Д.Ж. Құрманғалиев², Ә.Ш. Әбілғазиева¹, Н.Қ. Дукесова²

¹Сафи Әтебаев атындағы Атырау мұнай және газ университеті, Атырау қаласы, Қазақстан

²ҚМГ Инжиниринг, Астана қаласы, Қазақстан

АНДАТПА

Негіздеу. Соңғы онжылдықтарда жасанды интеллект (бұдан әрі – ЖИ) технологиялары геологиялық барлаудың, геофизикалық деректерді интерпретациялаудың, қабаттарды модельдеудің және кен орындарын игерудің негізгі кезеңдерін қамти отырып, мұнай-газ саласына тез енгізілуде. Үлкен деректерді талдаудың заманауи әдістері, машиналық оқыту және интеллектуалды басқару жүйелері геологиялық-геофизикалық және каротаждық деректерді түсіндірудің дәлдігін арттыруға, инженерлік шешімдер қабылдаудағы белгісіздік деңгейін төмендетуге, өндірістік тәуекелдерді азайтуға және көмірсутектерді барлау және өндіру процестерін оңтайландыруға мүмкіндік береді.

Мақсаты. Мақалада ұңғымаларды геофизикалық зерттеу деректерін (бұдан әрі – ҰГЗ) автоматтандырылған түсіндіру, жыныстардың литологиялық құрамын жіктеу, каротаждық қисықтарды қайта құру және геологиялық барлау процестерін цифрландыру міндеттеріне баса назар аударатын отырып, мұнай-газ индустриясында АИ қолданудың заманауи бағыттары қарастырылған. Геологиялық-геофизикалық ақпаратты каротаждау, өңдеу және түсіндіру саласында ЖИ технологияларын енгізудің әлемдік тәжірибесіне талдау жүргізілді, сондай-ақ жетекші халықаралық мұнай сервистік және мұнай-газ компанияларының интеграцияланған бағдарламалық шешімдері мен цифрлық платформалары қаралды.

Материалдар мен әдістер. ҰГЗ деректері бойынша литологияны автоматтандырылған жіктеу үшін «ҚМГ Инжиниринг» ЖШС-де машиналық оқыту әдістерін қолданудың тәжірибелік тәжірибесіне ерекше назар аударылды. Зерттеу барысында 100-ден астам ұңғымалардың деректері негізінде әртүрлі машиналық оқыту алгоритмдері, соның ішінде Logistic Regression, Random Forest, XGBoost және басқа машиналық оқыту алгоритмдері сыналды. Деректерді дайындау және тазарту, оқыту және тестілеу үлгілерін қалыптастыру ерекшеліктері, сондай-ақ тарихи геологиялық-геофизикалық деректердің толық подготовкисіздігі, гетерогенділігі және сапасының төмендігімен байланысты проблемалар қарастырылады.

Нәтижелері. Зерттеу нәтижелері ансамбльдік әдістер мен градиентті күшейту алгоритмдерін қолдану литологиялық типтерді жіктеудің жоғары дәлдігіне қол жеткізуге және каротаж деректерін түсіндіру процестерін тиімді автоматтандыруға мүмкіндік беретінін көрсетті. Ең жақсы нәтижелер нақты өндіріс деректері жағдайында жоғары тұрақтылық пен болжау сапасын көрсететін Random Forest алгоритмін пайдалану арқылы алынды. Литологияны жедел болжау және геологиялық-техникалық шешімдерді қабылдауды қолдау үшін оқытылған модельдерді корпоративтік ақпараттық жүйелерге интеграциялау мәселелері жеке қаралды.

Қорытынды. Жасанды интеллект технологияларын енгізу Қазақстанның мұнай-газ саласын цифрлық трансформациялаудың негізгі бағыттарының бірі болып табылады деген қорытынды жасалды. ЖИ пайдалану геологиялық барлау жұмыстарының тиімділігін арттыруға, деректерді өңдеуді және түсіндіруді жеделдетуге, көмірсутектерді алу коэффициентін арттыруға және геологиялық құрылымның күрделене түсуі мен ресурстық базаның сапасының нашарлауы жағдайында кен орындарын игеру шығындарын азайтуға мүмкіндік береді.

Негізгі сөздер: жасанды интеллект, машиналық оқыту, мұнай-газ саласы, ұңғымаларды геофизикалық зерттеу, ҰГЗ, каротаж, литология, Random Forest, XGBoost, автоматтандырылған интерпретация, цифрландыру, геологиялық барлау, нейрондық желілер, деректерді талдау, жыныстарды жіктеу.

Дәйексөз келтіру үшін:

Аяғанова А.І., Құрманғалиев Д.Ж., Әбілғазиева Ә.Ш., Дукесова Н.Қ. Мұнай-газ саласында жасанды интеллектті қолдану: тренд пе, әлде қажеттілік пе? // Қазақстанның мұнай-газ саласының хабаршысы. 2026. 8 том, №2, 59–73 б. DOI: [10.54859/kjogi108909](https://doi.org/10.54859/kjogi108909).

Введение

Нефтегазовая отрасль в современных условиях сталкивается с целым рядом серьезных вызовов: истощением традиционных месторождений, необходимостью разработки трудноизвлекаемых и труднодоступных залежей, а также высокой неопределенностью геологических данных. В этих условиях применение технологий ИИ перестаёт быть просто отраслевым трендом и становится объективной необходимостью, позволяющей повышать эффективность и рентабельность как разведочных, так и добычных работ.

За последние десять лет распространённость ИИ в нефтегазовой сфере, особенно в области геологии и геофизики, значительно возросла. Это обусловлено тем, что объёмы поступающих данных – геолого-геофизических, данных по разработке и добыче, технологических параметров – ежегодно растут в геометрической прогрессии. Обработка столь масштабных массивов информации традиционными методами требует значительных временных и кадровых ресурсов, что сдерживает оперативность принятия решений и увеличивает издержки. Именно поэтому во всём мире активно внедряются решения на базе ИИ и глубоких нейронных сетей, способные автоматизировать анализ и интерпретацию данных, сокращать сроки получения результатов, повышать точность прогнозов и снижать уровень неопределённости при принятии геолого-технических решений.

Таким образом, интеграция технологий ИИ в ключевые производственные процессы нефтегазовой отрасли уже сегодня выступает одним из важнейших инструментов повышения управляемости и эффективности разработки месторождений в условиях возрастающих технологических и экономических требований.

ИИ в каротаже

В процессе геологоразведки и разработки месторождений накапливается колоссальный объём информации, включая результаты ГИС, зачастую по всей глубине интервалов исследования с шагом 10 см и по множеству кривых: гамма-каротаж (далее – ГК или GR, *англ.* Gamma Ray), потенциал самопроизвольной поляризации (далее – ПС), нейтронный каротаж, нейтрон-нейтронный каротаж, гамма-гамма каротаж, боковой каротаж (далее – БК) и другие методы. Перед ИИ ставится одна из ключевых задач – прогнозирование литологического состава пород по данным каротажа.

Для реализации данной задачи в обучающие выборки систем ИИ включаются данные о свойствах пород и их классификационные признаки (литологические названия и характеристики). На сегодняшний день существует широкий

спектр алгоритмов ИИ, применяемых в специализированном геологическом анализе. Необходимые исходные данные для обучения таких моделей либо уже имеются в распоряжении компаний, либо могут быть получены в рамках текущих исследований.

Отдельное направление применения ИИ связано с восполнением недостающих данных по старым скважинам. Как известно, исторически часть скважин исследовалась ограниченным комплексом методов, что не позволяет в полной мере охарактеризовать геологический разрез. В подобных случаях технологии ИИ используются для восстановления и прогнозирования отсутствующих каротажных кривых и параметров на основе имеющихся данных, что позволяет повысить информативность существующего фонда скважин.

Одним из новых и перспективных направлений внедрения ИИ в геологии является автоматизированное описание кернового материала. С применением технологий компьютерного зрения и глубокого обучения стало возможным проводить первичный анализ фотографий керна с целью оперативного получения информации о текстуре, цвете, трещиноватости и других параметрах пород. Это позволяет существенно ускорить процесс обработки кернового материала и повысить его объективность за счёт минимизации влияния человеческого фактора.

Из-за неоднородности пластов, сложности объектов разведки и разнообразных условий проведения работ необходимо разрабатывать новые методы измерений и сбора данных, в частности, методы передачи параметров из скважины. Внедрение ИИ позволяет повысить точность, эффективность и безопасность работ.

Литературный обзор

Одним из ключевых направлений использования ИИ является интерпретация данных каротажа и сейсморазведки. Согласно исследованиям [1], глубокие нейросети, в частности, свёрточные (CNN, *англ.* Convolutional Neural Network – свёрточная нейронная сеть) и рекуррентные сети (RNN, *англ.* Recurrent Neural Network – рекуррентная нейронная сеть), успешно применяются для автоматической классификации геофизических аномалий и идентификации разломов в сейсмических данных [2]. Отмечается, что модели машинного обучения позволяют повышать точность анализа геологических характеристик, сокращая время обработки информации.

Применение алгоритмов сегментации изображений, таких как U-Net¹, позволяет автоматически выделять границы геологических объектов [3]. Однако, как указывают авторы, отсутствие размеченных данных остается ключе-

¹ U-Net — это CNN, созданная для семантической сегментации изображений. Она классифицирует изображение попиксельно, создавая точную маску объектов.

вой проблемой, ограничивающей дальнейшее развитие данной технологии.

ИИ также активно применяется в прогнозировании параметров пластов, таких как пористость, проницаемость и насыщенность [2]. В ранних работах использовались традиционные методы машинного обучения, включая метод опорных векторов (SVM, *англ.* Support Vector Machine) и линейную регрессию. В современных исследованиях отмечается рост применения глубоких нейросетей (BP (*англ.* Backpropagation – обратное распространение ошибки), LSTM (*англ.* Long Short-Term Memory – долгая краткосрочная память), случайных лесов (Random Forest) и градиентного бустинга (GBDT, *англ.* Gradient Boosting Decision Tree), что значительно повышает точность прогнозов [4].

Материалы и методы

В рамках настоящего исследования рассмотрены методы применения технологий искусственного интеллекта и машинного обучения для автоматизированной интерпретации данных ГИС и классификации литологического состава пород. Исследование основано на анализе фактических данных по нефтегазовым месторождениям Казахстана и включает как теоретический обзор современных подходов, так и практическое тестирование алгоритмов машинного обучения на реальных производственных данных.

В качестве исходных данных использовались результаты геофизических исследований скважин, представленные в формате LAS-файлов (*англ.* Log ASCII² Standard)³. В исследовании были включены данные более 100 скважин, содержащие стандартные каротажные параметры: ГК (GR), потенциал собственной поляризации (SP, *англ.* Spontaneous / Self-Potential), калвернометрию (CALI, *сокр. от англ.* Caliper Logging), удельное сопротивление пород (LLS, *англ.* Lateral Logging Sonde), а также глубинные привязки (DEPT, *от англ.* Depth – глубина) с шагом дискретизации 10 см. Дополнительно использовались результаты керновых исследований по 20 скважинам, применённые для сопоставления и валидации литологических классов.

На этапе подготовки данных выполнялись процедуры предварительной обработки, включающие объединение разрозненных источников информации, очистку данных от пропусков и аномальных значений, стандартизацию структуры данных и формирование единого массива для последующего анализа. Значительное внимание уделялось контролю качества исходной информации, поскольку наличие неполных и неоднородных данных является одной из основных проблем при внедрении ИИ в задачи геологораз-

ведки. В процессе обработки из исходного массива были исключены строки с отсутствующими значениями по ключевым параметрам, необходимым для обучения моделей.

Для повышения эффективности классификации использовались как исходные каротажные кривые, так и производные признаки, включая первую и вторую производные отдельных параметров, а также синтетические признаки, сформированные путём математических преобразований исходных данных. В качестве целевой переменной использовались литологические классы, сформированные по результатам интерпретации ГИС и анализа керна.

В исследовании были рассмотрены два варианта классификации пород: детализированная 10-классовая модель и укрупнённая 5-классовая схема, включающая основные типы литологии – песчаники, алевролиты и глинистые породы. Формирование обучающей и тестовой выборок осуществлялось с сохранением пропорций классов. Для предотвращения статистических перекосов разделение данных выполнялось не по отдельным записям, а по скважинам, что позволило исключить попадание данных одной и той же скважины одновременно в обучающую и тестовую выборки. Соотношение обучающей и тестовой выборок составило 70% и 30% соответственно.

Для построения и оценки моделей были протестированы различные алгоритмы машинного обучения, включая Logistic Regression (логистическая регрессия), Decision Tree (дерево решений), Random Forest, XGBoost (градиентный бустинг), LightGBM (метод градиентной бустинговой сборки) и другие методы классификации. В качестве основного критерия оценки качества использовались метрики Accuracy Score (метрика правильности), F1 Macro Score и F1 Weighted Score (метрики качества классификации). Дополнительно анализировались матрицы ошибок, показатели точности по отдельным классам и устойчивость моделей к вариативности входных данных.

Обучение и тестирование моделей проводились с применением методов перекрёстной проверки, позволяющих снизить риск переобучения и повысить обобщающую способность алгоритмов. Наилучшие результаты были получены при использовании ансамблевых методов, в частности, алгоритма Random Forest, продемонстрировавшего высокую точность классификации и устойчивость при работе с неполными и неоднородными геолого-геофизическими данными.

Практическая реализация исследования включала интеграцию обученной модели в ин-

² LAS – это формат файла для хранения информации о скважинном каротаже.

³ ASCII (*англ.* American Standard Code for Information Interchange – американский стандарт кодов для обмена информацией) – стандарт кодирования букв латинского алфавита, цифр, некоторых специальных знаков и управляющих символов, принятый в 1963 г. Американской ассоциацией стандартов как основной способ представления текстовых данных в электронных вычислительных машинах.

формационную систему ТОО «КМГ Инжиниринг» для оперативного прогнозирования литологии по данным каротажа. Разработанное решение обеспечивает автоматическую классификацию литологических интервалов и визуализацию результатов в виде цветокодированных колонок, сопоставимых с экспертной интерпретацией специалистов.

Сбор и обработка данных

Зарубежные компании уже коммерциализировали решения для сбора данных и удалённого каротажа. Например, компания Schlumberger разработала Центр удалённого каротажа (Remote Logging Center), интеллектуальный тестер формации (Intelligent Formation Tester) и программное обеспечение (далее – ПО) Techlog для интеллектуальной обработки и интерпретации данных [5]. Платформа iStar⁴ от Halliburton⁵ интегрирует автоматизацию, машинное обучение и ИИ для оценки запасов, что способствует более быстрому бурению и последовательной разработке месторождений [6]. В Китае нефтяные компании и научно-исследовательские институты ведут разработки в области сетевых наземных объектов, интеллектуальных лебедок, удалённого каротажа и начали применять первые результаты на практике. Также ведутся исследования по созданию интеллектуальных скважинных роботов [7].

В мире активно развиваются удалённые каротажные центры, позволяющие проводить дистанционные операции и экспертный анализ геолого-геофизических данных [5].

Автоматизированная интерпретация данных

Каротажные данные отличаются большим объёмом и разнородностью, что затрудняет интерпретацию и приводит к множественности решений и неопределённости. Это делает процесс выделения продуктивных зон более сложным. В связи с этим остро стоит необходимость применения технологий ИИ для повышения эффективности и точности интерпретации.

Применение ИИ в интерпретации каротажа охватывает автоматическую коррекцию глубины, автоматическое формирование отчётов, интеллектуальную стратификацию, реконструкцию кривых, идентификацию литологии, интерпретацию изображений каротажа, оценку параметров пластов, прогнозирование потенциала нефти и газа, предсказание скорости поперечной волны, идентификацию трещин и их заполнителей.

Реконструкция каротажных кривых основана на методах глубокого обучения, корреляционного анализа и других алгоритмах,

что позволяет восстанавливать некорректные или пропущенные данные. Применяются такие алгоритмы, как нейросети, алгоритмы ансамблевого обучения и кластеризации. Например, метод реконструкции каротажных кривых с использованием RNN и сети LSTM оказался более точным, чем традиционные методы [7].

Литологическая интерпретация возможна двумя способами:

1) Анализ образцов керн, включая фотошлифов, СТ (*англ.* Computed Tomography – компьютерная томография) и SEM (*англ.* Scanning Electron Microscope – сканирующий электронный микроскоп) изображения. Современные программные пакеты, например, Avizo⁶, могут автоматически определять литологию, но требуют значительных взаимодействий с оператором;

2) Определение литологии на основе каротажных кривых с использованием методов машинного обучения. Например, модель, построенная с использованием Boosting Tree, Decision Tree и Support Vector Machine, достигла точности более 80% при сравнении с результатами шлам-анализа.

При интерпретации изображений каротажа данные преобразуются в визуальные изображения с использованием цветовой калибровки. Современные исследования сочетают глубокое обучение с обработкой изображений для автоматического распознавания геологических структур. Например, алгоритмы U-Net позволяют автоматически выделять границы геологических объектов, что значительно упрощает процесс интерпретации. Однако недостаток размеченных данных ограничивает дальнейшее развитие этих технологий [8].

ИИ уже применяется для оценки параметров пластов, таких как пористость, проницаемость и насыщенность. Первые исследования использовали традиционные алгоритмы машинного обучения, такие как Support Vector Machine и линейную регрессию. Сегодня все больше учёных применяют BP, LSTM, Random Forest и GBDT для повышения точности расчётов [9].

В рамках практической деятельности в области интерпретации скважинных данных авторами настоящей статьи проводились работы по применению методов ИИ для решения задач, связанных с анализом и классификацией данных ГИС. На основании накопленного опыта можно выделить ряд ключевых положений и практических особенностей.

Любое построение корректной предсказательной модели с использованием ИИ начинается с тщательной оценки качества и структуры исходных данных. В первую очередь, как показывает практика, основным препятствием для успешно-

⁴ iStar – интеллектуальная платформа для бурения и каротажа скважин

⁵ Halliburton – американская транснациональная нефтесервисная компания

⁶ Avizo – это программный пакет для 3D-визуализации, обработки и анализа научных и промышленных данных. Он позволяет превращать сложные многомерные изображения (от микроскопии до компьютерной томографии) в количественные результаты и наглядные модели. Производитель Thermo Fisher Scientific, США.

го внедрения ИИ в задачи прогнозирования литологического состава пород по данным каротажа является отсутствие единой актуальной базы данных, а также неструктурированный характер хранения большого объема материалов с наличием ошибочных и неполных данных.

Данные хранятся разрозненно: результаты исследований зачастую представлены в отдельных таблицах с различной структурой, оформлением и форматом заполнения. Реальная практика показала, что для полноценного применения алгоритмов ИИ необходимо привести все данные к единому формату и объединить их в единый массив, пригодный для последующей обработки.

Основной задачей ГИС является выделение продуктивных зон в геологическом разрезе, в частности, определение таких параметров, как пористость, проницаемость, нефтенасыщенность, газонасыщенность и состав флюида. Особое значение имеют задачи, связанные с моделированием, поскольку литология напрямую влияет на построение гидродинамических моделей и определяет границы гидродинамических блоков, критически важных для эффективной разработки месторождения.

На практике анализ керна для определения состава породы требует значительных затрат времени и ресурсов, особенно с учётом необходимости бурения большого количества скважин. В этой связи были реализованы проекты по разработке и обучению моделей ИИ, способных определять состав породы по данным ГИС, без необходимости отбора керна.

Характеристики нефтяных скважин измеряются различными петрофизическими приборами. В рамках работы активно применялись такие параметры, как SP, CALI, GR, LLS и DEPT в качестве входных данных для построения моделей классификации.




Рисунок 1. Пример 10-классовой обучающей выборки

Figure 1. Example of a 10-class training dataset

В 2020 г. в рамках совместного проекта специалистов ТОО «КМГ Инжиниринг» впервые на практике были протестированы и опробованы алгоритмы машинного обучения для классификации состава пород по данным месторождений АО НК «КазМунайГаз». На основании этого опыта

было установлено, что классические нейронные сети не обеспечивают достаточного качества классификации и не подходят для практического применения в задачах геологоразведки в текущих условиях.

На этапе тестирования выявились ключевые особенности разбиения данных: в первоначальных экспериментах разбиение осуществлялось по записям, а не по скважинам, что приводило к статистическим перекосам. Например, данные по одной скважине могли одновременно находиться как в обучающей, так и в тестовой выборке, что искажало итоговые метрики качества. В результате точность модели на тестовой выборке опускалась до 30%. В дальнейшем было принято решение о разбиении данных строго по скважинам, несмотря на уменьшение объема тестовой выборки.

В рамках этого же проекта была разработана и обучена модель классификатора на 10 пород. Для построения модели использовались два набора данных:

- данные по керну (20 скважин с 9 породами);
- данные по интерпретации ГИС (100 скважин с 10 породами).

После предварительной очистки от пропусков по шести основным признакам (SP, CALI, GR, LLS, DEPT) в выборке осталось 98 скважин. Очистка данных предполагала полное исключение записей с отсутствующими кривыми по любому из параметров. Шаг дискретизации по глубине составлял 10 см. В результате было сформировано около 450 тысяч строк по ГИС, из которых 115 тысяч строк содержали метки литологии и использовались для обучения и валидации модели.

Из опыта следует, что CALI, GR, LLS, SP и DEPT выступают ключевыми переменными для построения рабочей модели классификации литологии. При этом наилучшие результаты были достигнуты при применении методов градиентного бустинга и ансамблевых моделей, а также с использованием более сложных архитектур глубоких нейронных сетей для обработки больших массивов данных.

Полученный опыт подтвердил, что несмотря на существующие ограничения и сложности, применение технологий ИИ в интерпретации скважинных данных ГИС в реальных условиях Казахстана является перспективным направлением, требующим дальнейшего развития и тиражирования на уровне производственных структур.

По результатам анализа данных по 20 скважинам, для которых осуществлялся отбор керна, была выполнена попытка выделения литологии и последующего использования полученных данных в качестве обучающей выборки для построения модели ИИ. В рамках данного этапа работы по керновому материалу было классифицировано 9 пород, отражающих различия в литологическом составе пород.

Однако практика показала, что обучение модели исключительно на данных керна не обе-

спечивает необходимой точности и устойчивости результатов из-за ограниченного объёма выборки и недостаточного количества представленных образцов по каждому из классов. В связи с этим для дальнейшего обучения и повышения каче-

ства модели было принято решение использовать расширенную выборку, основанную на данных ГИС, которые включали те же интервальные характеристики, что и керн.




Рисунок 2. 5- и 10-классовые модели
Figure 2. 5-class and 10-class models

а) 5-классовый вариант / 5-class version; б) 10-классовый вариант / 10-class version

В результате была сформирована 10-классовая обучающая выборка по данным ГИС, отражающая выделенные ранее породы. На рис. 1 продемонстрирован пример такой выборки, где визуально видно, что часть пород хорошо разделяется по литологическим признакам, тогда как для других классов наблюдается частичное пересечение характеристик. Это указывает на необходимость дальнейшего уточнения методов предобработки и подбора оптимальных алгоритмов для повышения точности классификации.

Объединение выделенных по ГИС пород в породы по керну представляет собой самостоятельную задачу, обусловленную тем, что каждая порода по керновым данным является сложной структурой, состоящей из ряда взаимопересекающихся пород, расположенных в определённой последовательности.

В качестве примера приведено преобразование 10-классовой классификации пород в 5-классовую классификацию пород:

1. Класс 1 (песчаник крупнозернистый) соответствует 1-му классу пород.
2. Класс 2 (песчаник мелкозернистый) объединяет 2-й, 3-й и 4-й классы пород.
3. Класс 3 (алевролит) представлен 5-м классом пород.
4. Класс 4 (глинистый алевролит) включает 6-й, 7-й и 8-й классы пород.
5. Класс 5 (глина) объединяет 9-й и 10-й классы пород.

В обоих вариантах классификации разделение исходного набора данных на обучающую и валидационную выборки сохраняло исходные пропорции классов и не выявило значимого дисбаланса данных, в связи с чем применение методов балансировки выборки (таких как upscaling

или downscaling) не предполагается. Соотношение тренировочной и тестовой выборок принято равным 70% и 30% соответственно.

Гистограммы для 5-классового и 10-классового вариантов представлены на рис. 2. Такой формат графического представления позволяет легко сравнить распределение данных по классам для тренировочной и тестовой выборок.

Для решения задачи автоматической классификации литологии на основе геофизических данных использованы два набора данных, представленных в формате LAS-файлов:

1. Набор 1: 20 скважин, данные основаны на результатах исследований керна (целевой признак – 9 классов).

2. Набор 2: 100 скважин, данные основаны на интерпретации ГИС, целевой признак – 10 классов.

В качестве признаков использовались стандартные параметры ГИС: SP, LLS, GR, CALI, DEPT (глубина с шагом 10 см).

Для повышения устойчивости модели и учёта геологической специфики было выполнено укрупнение исходных 10 классов до 5 обобщённых классов, ранее описанных выше.

Проведённые предварительные эксперименты показали, что обучение моделей на наборе 1 (по данным керна) не обеспечивает приемлемого качества классификации, выраженного через метрику «сходимость» (максимальное значение в диапазоне 0,55–0,60). В связи с этим в дальнейших расчётах использовался исключительно набор 2, основанный на данных интерпретаций ГИС, позволяющий получить более стабильные и воспроизводимые результаты.

Ключевая задача проекта заключалась в разработке моделей именно для данных, осно-

ванных на ГИС, что позволяет масштабировать методику на полный фонд скважин. Для обеспечения качества итоговых моделей необходимо предусмотреть доступ к достаточному объёму данных керновых исследований для валидации и контроля обученных моделей (рис. 3).

В процессе подготовки исходных данных для построения моделей было загружено 100 скважин, что соответствует общему объёму в 1900000 строк. При этом значительная часть данных содержала пропуски различной природы. По результатам анализа установлено, что:

- полностью пустыми оказались около 452 тысячи строк (~25% от общего объёма);
- в 925 тысячах строк были неполные данные по ГИС-кривым;

– остаток после удаления пустых строк составил около 452 тысячи строк.

Из оставшихся данных только 115 тысяч строк (примерно 8% от исходного объёма) содержат полный набор необходимых признаков и могут быть использованы для обучения и валидации моделей. Остальные 337 тысяч строк допустимо использовать лишь для прогнозных расчётов без последующей проверки качества.

Статистика по признакам показала следующие средние проценты пропусков:

- целевая переменная – около 94%;
- CALI – около 33%;
- GR – около 26%;
- SP – около 75%;
- LLS – около 43%.

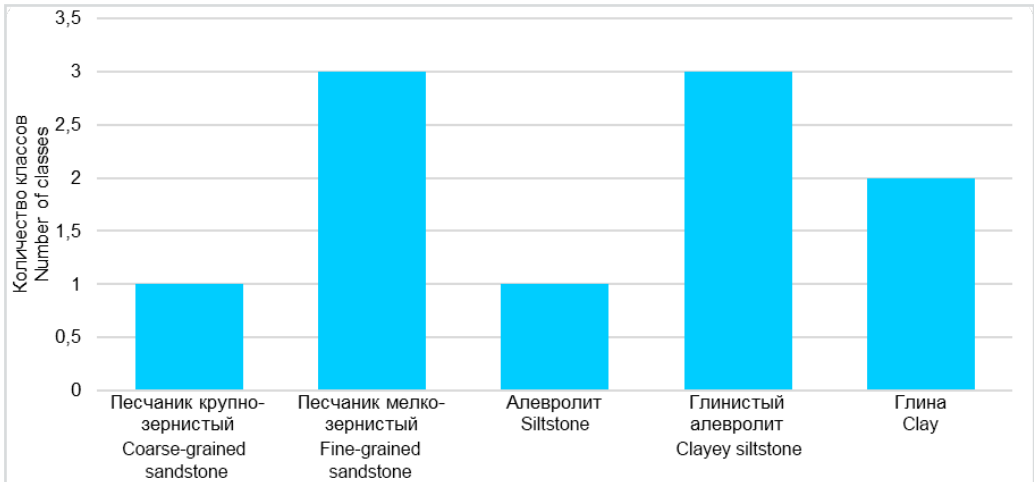


Рисунок 3. Группировка классов
Figure 3. Class grouping

Таким образом, изначально большой объём сырых данных значительно сокращается после обработки и удаления пропусков, что необходимо учитывать при построении и тестировании моделей машинного обучения.

Данные были разделены на обучающую и тестовую выборки. Тестовая выборка использовалась для проведения перекрёстной проверки с целью подбора оптимальных параметров модели. При этом данные теста применялись исключительно для оценки обобщающей способности модели и не использовались в процессе обучения.

В задачах контролируемого процесса обучения часто возникают проблемы смещения и дисперсии модели. Перекрёстная проверка позволяет сбалансировать эти характеристики, снижая переобучение и повышая устойчивость модели к особенностям конкретного набора данных.

В рамках исследования были протестированы следующие алгоритмы машинного обучения (табл. 1–2):

- Logistic Regression – использовалась в качестве базовой (vanilla) модели для целей

сравнения. Является простым и быстрым алгоритмом, эффективно выявляющим линейные зависимости;

- Random Forest – мощный ансамблевый метод, хорошо работающий на различных типах данных. Однако обученные модели могут занимать значительный объём памяти;

- XGBoost – адаптивный градиентный бустинг, демонстрирующий высокую эффективность и скорость среди моделей своего класса. Отличается хорошим балансом между точностью и вычислительной сложностью.

Согласно результатам экспериментов, наилучшие показатели качества продемонстрировали модели Random Forest и XGBoost. При этом XGBoost обучается существенно дольше, но генерирует более компактную модель: например, модель Random Forest занимала около 18 ГБ памяти.

Для задачи ранжирования скважин была выбрана обученная модель на основе Random Forest с параметрами: число деревьев – 250 ед.;

- максимальная глубина деревьев – 45 ед.;

Таблица 1. Сравнительная таблица рассматриваемых алгоритмов (10-классовая)
Table 1. Comparative table of the considered algorithms (10-class)

Показатели / Metrics	Logistic Regression	Random Forest	XG-Boost
Точность Accuracy Score	0,23	0,81	0,81
Среднее F1 Macro Score	0,17	0,81	0,81
Средневзвешенное F1 Weighted Score	0,19	0,81	0,81
Размер модели Model Size	0,02 mb	2 321 mb	609 mb
Скорость Predict Speed (s)	0,01	4,3	129,7

• размер модели – 619 Мб для выборки с 5 классами и 2321 Мб для выборки с 10 классами;

• точность модели (метрика качества на тестовой выборке) составила 0,9 и 0,8 соответственно.

В качестве признаков использовались как исходные геофизические кривые, так и производные признаки, такие как первая и вторая производные кривой SP, а также синтетические признаки, полученные с помощью арифметических операций над исходными данными.

В дополнение к Random Forest и XGBoost были протестированы также алгоритмы LightGBM, Decision Tree, Linear Regression и др. По итогам сравнения наилучшие результаты показал алгоритм Random Forest, достигнув значения метрики качества 0,9.

В рамках данного исследования в качестве оптимального решения для поставленной задачи был выбран алгоритм Random Forest, продемонстрировавший наилучшее соотношение точности и вычислительной эффективности. Хотя алгоритм XGBoost показал аналогичные метрики качества, предпочтение было отдано Random Forest с учётом вышеописанного.

С учётом минимального целевого порога точности (точность > 0,85), была выбрана модель классификации с разделением на 5 классов. Такой подход обеспечил требуемый уровень обобщающей способности при сохранении интерпретируемости результатов.

Следует подчеркнуть, что представленные решения по выбору количества классов, алгоритма и его параметров не следует рассматривать как универсальные для более масштабных или разнородных наборов данных. Проведённый анализ ориентирован исключительно на демонстрацию предсказательной способности моделей в рамках данного проекта, ограниченного выборкой из 100 скважин.

Оценка производительности модели Random Forest на тестовой выборке показала высокий уровень точности (0,9) при использовании 5-классовой схемы классификации, что под-

Таблица 2. Сравнительная таблица рассматриваемых алгоритмов (5-классовая)
Table 2. Comparative table of the considered algorithms (5-class)

Показатели / Metrics	Logistic Regression	Random Forest	XG-Boost
Точность Accuracy Score	0,49	0,90	0,90
Среднее F1 Macro Score	0,34	0,88	0,88
Средневзвешенное F1 Weighted Score	0,46	0,90	0,90
Размер модели Model Size	0,02 mb	619 mb	134 mb
Скорость Predict Speed (s)	0,01	1,7	40,0

тверждает её применимость для ранжирования объектов в рассматриваемом контексте.

Для более детального анализа качества классификации были рассчитаны показатели точности по каждому классу как для модели Random Forest, так и для логистической регрессии (табл. 3). Средняя точность модели Random Forest составила 0,90, что значительно превышает соответствующий показатель логистической регрессии – 0,63.

Таблица 3. Сравнение двух моделей
Table 3. Comparison of two models

Параметры сравнения Comparison Parameters	Точность / Accuracy	
	Random Forest	Logistic Regression
Средняя Average	0,90	0,63
Точность по классу №1 Accuracy class No. 1	0,92	0,55
Точность по классу №2 Accuracy class No. 2	0,92	0,78
Точность по классу №3 Accuracy class No. 3	0,75	0,61
Точность по классу №4 Accuracy class No. 4	0,89	0,66
Точность по классу №5 Accuracy class No. 5	0,93	0,57

Разбивка по классам показала, что модель Random Forest демонстрирует устойчиво высокую точность для большинства категорий. Так, для классов №1, №2 и №5 точность составила 0,92, 0,92 и 0,93 соответственно. Несколько ниже точность наблюдается для класса №3 (0,75), что, вероятно, связано с его внутренней неоднородностью или ограниченным числом объектов в выборке. Тем не менее и в этом случае Random Forest превосходит логистическую регрессию, точность которой по данному классу составляет 0,61.

По всем пяти классам модель Random Forest обеспечивает стабильное и высокое качество классификации, тогда как логистическая регрессия демонстрирует более выраженную вариативность и менее удовлетворительные результаты – от 0,55 до 0,78.

Таким образом, сравнение точности по классам подтверждает преимущество алгоритма Random Forest в рассматриваемой задаче классификации скважин по выделенным категориям.

На рис. 4 представлены распределения точности для моделей Random Forest и логистической регрессии. График демонстрирует распределение точности моделей Random Forest и логистической регрессии.

Синяя кривая и столбцы – Random Forest: точность сконцентрирована в диапазоне 0,93–0,99, что свидетельствует о высокой стабильности и качестве модели. Оранжевая кривая и столбцы – Logistic Regression: точность распределена шире и смещена к более низким

значениям (около 0,49), что указывает на худшую предсказательную способность.

Анализ матриц ошибок показывает, что каждая из рассмотренных моделей демонстрирует различное поведение при классификации отдельных литологических классов. В целом, наибольшая точность достигается при распознавании песчаника, алевролита и глин, в то время как другие классы определяются менее уверенно.

Особенно стоит отметить, что глины стабильно показывают наивысшие значения F1-метрики при использовании как контролируемых, так и неконтролируемых алгоритмов. Это преимущество объясняется более широкой представленностью глин в разрезе, что обеспечивает лучшее обучение моделей на этом классе.




Рисунок 4. Сравнение двух моделей
Figure 4. Comparison of two models

На рис. 5 представлена визуализация результатов классификации фаций, полученных в результате применения обученной модели машинного обучения. Колонки с первой по пятую отражают входные каротажные параметры, используемые при обучении модели: ГК, БК, коэффициент водонасыщенности, ПС и нормализованный ПС соответственно. Эти параметры представляют собой основную информацию о литологическом разрезе скважины и служат входными признаками для алгоритма классификации.

Шестая колонка содержит прогнозные данные по фациям, полученные с помощью обученной модели. В седьмой колонке приведены эталонные данные, полученные по результатам интерпретации профильными специалистами. Восьмая колонка отображает фации в виде цветовой шкалы (от 1 до 5), где каждому классу соответствует определённый цвет, что облегчает визуальное сопоставление между прогнозом и экспертной интерпретацией.

Сравнительный анализ показывает высокую степень сходимости между результатами, полученными моделью, и экспертной интерпретацией, включая как тонкослоистые, так и более протяжённые литологические интервалы. Коэффициент сходимости между модельной классификацией и экспертной разметкой на данной

скважине приближается к 1, что свидетельствует о высокой точности и надёжности применённого подхода.

Таким образом, использование алгоритмов машинного обучения демонстрирует высокую эффективность в автоматизированной интерпретации фаций на основе стандартных каротажных данных и может служить надёжным инструментом в геологоразведочной практике.

На текущий момент данная модель внедрена в информационную систему (далее – ИС) ТОО «КМГ Инжиниринг», предназначенную для оперативного прогнозирования литологии по каротажным данным (используется 4 и 6 кривых). Скважинные данные загружаются в ИС. Далее обученная модель классифицирует каждый метр разреза, присваивая ему один из заранее определённых литологических типов. Результаты выводятся в виде цветокодированных колонок, сопоставимых с ручной интерпретацией специалистов, что позволяет оперативно корректировать стратиграфические модели и уточнять границы пластов (рис. 6).

ИС обеспечивает визуализацию всех этапов – от исходных каротажных кривых до прогнозируемых литологий – в едином окне. Это позволяет быстро оценивать изменения фациальной обстановки.




Рисунок 5. Использование обученной модели по сравнению с человеком
Figure 5. Application of the trained model in comparison with human interpretation

Подобные подходы уже реализуются в интегрированном ПО в разных компаниях (Dream Cloud⁷ и CIFLog⁸).

Таким образом, использование машинного обучения в сочетании с современными информационными системами позволяет повысить точность и скорость интерпретации каротажных данных, снизить зависимость от субъективного фактора и обеспечить постоянное улучшение прогностических моделей за счёт накопления новой информации.

Интегрированные программные решения

Крупнейшие мировые компании, такие как Schlumberger, разрабатывают интегрированные программные комплексы. Например, DELFI – это платформа для когнитивной разведки и разработки месторождений, включающая обработку и интерпретацию данных, стандартизацию, очистку и анализ. ПО Techlog позволяет анализировать каротажные данные с помощью интеллектуальных алгоритмов.

⁷ Dream Cloud Collaboration Platform – промышленная облачная платформа CNPC для цифровой трансформации и совместной работы нефтегазовых предприятий.

⁸ CIFLog – это программная платформа для обработки и интерпретации данных ГИС, разработанная CNPC.




Рисунок 6. Использование внедренных моделей в ИС
Figure 6. Application of implemented models in information systems

В Китае разрабатываются собственные платформы, такие как Dream Cloud Collaboration Platform от CNPC⁹, LEAD¹⁰ и CIFlog. Развиваются технологии ИИ для моделирования пластов, интерпретации каротажа и геонавигации при бурении горизонтальных скважин [6].

Оборудование для геофизической разведки

Исследования в области ИИ и геофизической разведки стремительно развиваются по всему миру. Геофизическая разведка исторически является одной из первых отраслей, где использовались цифровые технологии, включая высокопроизводительные вычисления, трехмерную визуализацию и компьютерные сети.

ИИ применяется в оборудовании для геофизической разведки, включая вибросейсморазведку, беспилотники и сейсмическую аппаратуру.

Интеллектуальная вибросейсморазведка позволяет адаптировать параметры работы (мощность, диапазон частот, время сканирования и фазу) в зависимости от условий на поверхности и глубинных геологических характеристик, повышая безопасность и снижая нагрузку на окружающую среду.

Беспилотники используются для сбора геофизических данных, детальной топографической съёмки, оценки рисков, мониторинга узловых точек, восстановления данных, доставки оборудования и спасательных операций.

Современные сейсмические системы включают проводные (G3i¹¹) и беспроводные (OBN (англ. Ocean Bottom Node – донный сейсмичес-

кий узел), Hawk¹², eSeis¹³) решения. Технологии OBN позволяют преодолевать ограничения, связанные с шумами, плохой проходимостью местности и узким диапазоном наблюдений.

Заключение

Для Казахстана, обладающего крупными нефтегазовыми месторождениями, такими как Тенгиз, Кашаган и Карачаганак, внедрение ИИ в разведку и разработку – это не просто тренд, а реальная необходимость. Мы сталкиваемся с серьезными вызовами: сложные геологические условия, высокая неоднородность пластов, возрастающие затраты на добычу и необходимость более рационального использования ресурсов.

ИИ уже помогает нашей нефтегазовой отрасли решать эти задачи. Автоматизированный анализ геологоразведочных данных, прогнозирование продуктивности скважин и моделирование пластов на основе машинного обучения позволяют нам повышать эффективность работы. Казахстанские компании начинают активно использовать технологии цифровых двойников, интеллектуального управления добычей и автоматизированной интерпретации сейсмических данных [10–12].

Наша страна уверенно движется в сторону цифровизации нефтегазовой отрасли. В условиях глобальной конкуренции и требований устойчивого развития нам необходимо активнее внедрять ИИ, чтобы повышать коэффициент извлечения нефти, снижать издержки и минимизировать экологическое воздействие. ИИ – это не просто инструмент, а один из ключей к будущему нашей энергетики.

⁹ CNPC (англ. China National Petroleum Corporation) – Китайская национальная нефтегазовая корпорация.

¹⁰ LEAD (англ. Log Evaluation & Application Desktop) – интегрированное ПО для каротажной обработки и интерпретации, разработанное CNPC.

¹¹ G3i – это системы сбора и регистрации данных, разработанная INOVA.

¹² Hawk – это мультифункциональный инструмент наземной сеймики, автономная нодальная система.

¹³ eSeis – беспроводная сейсморазведочная система, разработанная дочерней структурой CNPC.

ДОПОЛНИТЕЛЬНО

Источник финансирования. Авторы заявляют об отсутствии внешнего финансирования при проведении исследования.

Конфликт интересов. Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Вклад авторов. Все авторы подтверждают соответствие своего авторства международным критериям ICMJE (все авторы внесли существенный вклад в разработку концепции, проведение исследования и подготовку статьи, прочли и одобрили финальную версию перед публикацией). Наибольший вклад распределён следующим образом: Аяганова А.И. – разработка структуры статьи, анализ результатов исследования, подготовка рукописи; Курмангалиев Д.Ж. – сбор и обработка данных, разработка и тестирование моделей машинного обучения; Абилгазиева А.Ш. – проведение литературного обзора, сравнительный анализ научных источников; Дукесова Н.К. – валидация результатов исследования, научное редактирование и финальная проверка рукописи.

ADDITIONAL INFORMATION

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. The greatest contribution is distributed as follows: Anar I. Ayaganova – development of the article structure, analysis of the research results, and preparation of the manuscript; Darkhan Zh. Kurmangaliyev – data collection and processing, development and testing of machine learning models; Aliya Sh. Abilgazyieva – conducting the literature review and comparative analysis of scientific sources; Nadezhda K. Dukessova – validation of the research results, scientific editing, and final revision of the manuscript.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Alaudah Y., Alfarraj M., AlRegib G. Machine learning for characterization of subsurface geology from seismic images // *Journal of Applied Geophysics*. 2019. Vol. 164. P. 225–239. doi: [10.1016/j.jappgeo.2019.02.005](https://doi.org/10.1016/j.jappgeo.2019.02.005).
2. Qi J., Zhang B., Lyu B. Seismic attribute selection for machine-learning-based facies analysis // *Geophysics*. 2020. Vol. 85, N 2. P. 017–035. doi: [10.1190/geo2019-0223.1](https://doi.org/10.1190/geo2019-0223.1).
3. Ронкин М.В., Акимова Е.Н., Мислов В.Е., Решетников К.И. Обзор применения глубоких нейронных сетей и параллельных архитектур в задачах фрагментации горных пород // *Вестник ЮУГУ. Серия «Вычислительная математика и информатика»*. 2023. Т. 12, №4. С. 5–54. doi: [10.14529/cmse230401](https://doi.org/10.14529/cmse230401).
4. slb.com [интернет]. SLB. Techlog Wellbore Software Platform [дата обращения 12.02.2025]. Доступ по ссылке: www.slb.com/products-and-services/delivering-digital-at-scale/software/techlog
5. slb.com [интернет]. SLB. Remote Operations and Digital Logging Solutions [дата обращения 12.02.2025]. Доступ по ссылке: www.slb.com
6. neftegaz.ru [интернет]. ИА Neftegaz.RU. Halliburton представила интеллектуальную цифровую платформу для бурения и каротажа скважин [дата обращения 12.02.2025]. Доступ по ссылке: neftegaz.ru/news/Oborudovanie/701778-halliburton-predstavila-intellektualnyuyu-tsifrovuyu-plattformu-diya-bureniya-i-karotazha-skvazhin/?ysclid=m8vzcjbz7594922150.
7. Kaur H., Pham N., Fomel S., et al. A deep learning framework for seismic facies classification // *Interpretation*. 2022. Vol. 11, N 4. P. 1–47. doi: [10.1190/int-2022-0048.1](https://doi.org/10.1190/int-2022-0048.1).
8. Абдуллина К.М., Спивак А.И. Применение нейронной сети архитектуры U-NET для задачи локализации нарушений целостности цифровых изображений // *Научно-технический вестник информационных технологий, механики и оптики*. 2020. Т. 20, №3. С. 425–431. doi: [10.17586/2226-1494-2020-20-3-425-431](https://doi.org/10.17586/2226-1494-2020-20-3-425-431).
9. Волков С.С., Курочкин И.И. Применение глубоких нейронных сетей, основанных на LSTM, для решения задач классификации // *Международная научно-техническая конференция «Перспективные информационные технологии»*; 24–27 Май, 2021; Самара, Россия. Режим доступа: repo.ssau.ru/jspui/handle/123456789/2911.
10. kmg.kz [интернет]. АО НК «КазМунайГаз». Интеллектуальные месторождения. Кейсы КМГ [дата обращения 25.02.2025]. Доступ по ссылке: www.kmg.kz/ru/press-center/articles/intellectual-fields-cases/.
11. tengizchevroil.com [интернет]. ТШО. В Тенгизшевройл рассказали, как используется искусственный интеллект [дата обращения 25.02.2025]. Доступ по ссылке: www.tengizchevroil.com/ru/tco-news/detail/2024/04/06/how-artificial-intelligence-is-used-in-tengizchevroil.
12. forbes.kz [интернет]. Forbes Kazakhstan. «Каспий нефть»: цифровизация месторождения и социальная ответственность бизнеса [дата обращения 25.02.2025]. Доступ по ссылке: forbes.kz/articles/kaspiy_neft_tsifrovizatsiya_mestorojdeniya_zabota_o_kdrah_i_regione.

REFERENCES

1. Alaudah Y, Alfarraj M, AlRegib G. Machine learning for characterization of subsurface geology from seismic images. *Journal of Applied Geophysics*. 2019;164:225–239. doi: [10.1016/j.jappgeo.2019.02.005](https://doi.org/10.1016/j.jappgeo.2019.02.005).
2. Qi J, Zhang B, Lyu B. Seismic attribute selection for machine-learning-based facies analysis. *Geophysics*. 2020;85(2):017–035. doi: [10.1190/geo2019-0223.1](https://doi.org/10.1190/geo2019-0223.1).

3. Ronkin MV, Akimova EN, Misilov VE, Reshetnikov KI. Review on Application of Deep Neural Networks and Parallel Architectures for Rock Fragmentation Problems. *Bulletin of the South Ural State University. Series: Computational Mathematics and Software Engineering*. 2023;12(4):5–54. doi: [10.14529/cmse230401](https://doi.org/10.14529/cmse230401). (In Russ).
4. slb.com [Internet]. SLB. Techlog Wellbore Software Platform [cited 2025 Feb 12]. Available from: www.slb.com/products-and-services/delivering-digital-at-scale/software/techlog
5. slb.com [Internet]. SLB. Remote Operations and Digital Logging Solutions [[cited 2025 Feb 12]. Available from: www.slb.com
6. neftegaz.ru [Internet]. Neftegaz.RU. Halliburton unveils Intelligent digital platform for drilling and logging wells [cited 2025 Feb 12]. Available from: neftegaz.ru/news/Oborudovanie/701778-halliburton-predstavila-intellektualnuyu-tsifrovuyu-platfomu-dlya-bureniya-i-karotazha-skvazhin/?ysclid=m8vzcyjblz7594922150. (In Russ).
7. Kaur H, Pham N, Fomel S, et al. A deep learning framework for seismic facies classification. *Interpretation*. 2022;11(4):1–47. doi: [10.1190/int-2022-0048.1](https://doi.org/10.1190/int-2022-0048.1).
8. Abdullina KM, Spivak AI. U-NET Architecture Neural Network for Localization of Digital Images Integrity Violation. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*. 2020;20(3):425–431. doi: [10.17586/2226-1494-2020-20-3-425-431](https://doi.org/10.17586/2226-1494-2020-20-3-425-431).
9. Volkov SS, Kurochkin II. *Primeneniye glubokih neyronnykh setey, osnovannykh na LSTM, dlya resheniya zadach klassifikatsii*. International Scientific Conference Proceedings “Advanced Information Technologies and Scientific Computing”; 2021 May 24–27; Samara, Russia. Available from: repo.ssau.ru/jspui/handle/123456789/2911. (In Russ).
10. kmg.kz [Internet]. KazMunayGas. Intellektual'nyye mestorozhdeniya. Keysy KMG [cited 2025 Feb 25]. Available from: www.kmg.kz/ru/press-center/articles/intellectual-fields-cases/. (In Russ).
11. tengizchevroil.com [Internet]. TCO. How artificial intelligence is used in Tengizchevroil [cited 2025 Feb 25]. Available from: www.tengizchevroil.com/ru/tco-news/detail/2024/04/06/how-artificial-intelligence-is-used-in-tengizchevroil. (In Russ).
12. forbes.kz [Internet]. Forbes Kazakhstan. Caspian Oil: Digitalization of the Field and Corporate Social Responsibility [cited 2025 Feb 25]. Available from: forbes.kz/articles/kaspiy_neft_tsifrovizatsiya_mestorojdeniya_zabota_o_kadrah_i_regione. (In Russ).

ИНФОРМАЦИЯ ОБ АВТОРАХ

Аяганова Анар Изгалиевна

ORCID [0009-0009-9712-6737](https://orcid.org/0009-0009-9712-6737)

e-mail: anar.ayaganova@aogu.edu.kz.

Курмангалиев Дархан Жунусканович

ORCID [0009-0000-6898-1907](https://orcid.org/0009-0000-6898-1907)

e-mail: d.kurmangaliyev@kmg.kz.

Абилгазиева Алия Шаймерденовна

ORCID [0009-0001-8496-6931](https://orcid.org/0009-0001-8496-6931)

e-mail: aliya-abilgaz@mail.ru.

***Дукессова Надежда Куандыковна**

ORCID [0009-0009-7198-731X](https://orcid.org/0009-0009-7198-731X)

e-mail: n.dukessova@kmg.kz.

AUTHORS' INFO

Anar I. Ayaganova

ORCID [0009-0009-9712-6737](https://orcid.org/0009-0009-9712-6737)

e-mail: anar.ayaganova@aogu.edu.kz.

Darkhan Zh. Kurmangaliyev

ORCID [0009-0000-6898-1907](https://orcid.org/0009-0000-6898-1907)

e-mail: d.kurmangaliyev@kmg.kz.

Aliya Sh. Abilgazyeva

ORCID [0009-0001-8496-6931](https://orcid.org/0009-0001-8496-6931)

e-mail: aliya-abilgaz@mail.ru.

***Nadezhda K. Dukessova**

ORCID [0009-0009-7198-731X](https://orcid.org/0009-0009-7198-731X)

e-mail: n.dukessova@kmg.kz.

*Автор, ответственный за переписку / Corresponding Author