УДК 5553.98:004.8; https://doi.org/10.37878/2708-0080/2026-3.03
https://orcid.org/0009-0009-5239-9918
https://orcid.org/0000-0003-0781-2434

ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ЛИТОЛОГИЧЕСКОЙ КЛАССИФИКАЦИИ КОЛЛЕКТОРОВ ДЖУНГАРСКОГО БАССЕЙНА

Н. ТІЛЕУБЕРДІ,
PhD, доцент,
n.tileuberdi@satbayev.university

Ч. ВЭЙ,
докторант,
2604637142@qq.com.

SATBAYEV UNIVERSITY,
Республика Казахстан, 050013, г. Алматы, ул. Сатпаева, 22а

В данной статье проведён систематический обзор литературы по применению искусственного интеллекта (ИИ) для литологической классификации глубокозалегающих сложных коллекторов с акцентом на методы интеллектуальной интерпретации геофизических исследований скважин (ГИС).

Полученные результаты на основе анализа многоэтапной тектонической эволюции Джунгарского бассейна и логики науки о данных выполнена междисциплинарная деконструкция наборов данных ГИС по 9 каротажным параметрам; впервые с позиции математических механизмов и геофизического отклика проведено сравнение классификации и сходимости алгоритмов Random Forest (RF) и XGBoost в сложных нелинейных геологических пространствах. Обобщение существующих исследований показывает, что обе модели демонстрируют высокую точность при дифференциации литотипов плотных песчано-гравийных коллекторов (свита Байкоуцюань впадины Маху), при этом XGBoost системно превосходит RF в минимизации остаточного градиента и выявлении скрытых закономерностей.

Практическое применение результатов создают методологическую основу для автоматизированной интерпретации данных ГИС, способствуют переходу нефтегазовой разведки от эмпирической парадигмы к интеллектуальному управлению и помогают раскрыть принцип «чёрного ящика» машинного обучения.

КЛЮЧЕВЫЕ СЛОВА: *Джунгарский бассейн, машинное обучение, алгоритм XGBoost, литологическая классификация, геофизические исследования скважин, ансамблевое обучение.*

ЖОҢҒАР ОЙПАТЫНДАҒЫ КОЛЛЕКТОРЛАРДЫҢ ЛИТОЛОГИЯЛЫҚ ЖІКТЕЛУІНДЕ МАШИНАЛЫҚ ОҚЫТУ АЛГОРИТМДЕРІН ҚОЛДАНУ

Н. ТІЛЕУБЕРДІ, PhD, доцент, *n.tileuberdi@satbayev.university*
Ч. ВЭЙ, докторант, *2604637142@qq.com*

SATBAYEV UNIVERSITY,
Қазақстан Республикасы, 050013, Алматы қ., Сәтпаев к., 22а

Бұл мақалада терең жатқан күрделі жинауыштардың литологиялық классификациясына жасанды интеллектті (ЖИ) қолдану бойынша әдебиеттерге жүйелі шолу жасалған, негізгі назар геофизикалық зерттеу деректерін интеллектуалды түсіндіру әдістеріне аударылған.

Алынған нәтижелер Жоңғар ойысының көпсатылы тектоникалық эволюциясы мен деректану логикасын біріктіре отырып, 9 каротаждық параметр бойынша ГИС деректер жиынтығына пәнаралық деконструкция жасалды; математикалық механизмдер мен геофизикалық жауап тұрғысынан алғаш рет күрделі сызықты емес геологиялық кеңістіктерде Random Forest (RF) және XGBoost алгоритмдерінің классификациясы мен жинақтылығы салыстырылды. Бар зерттеулерді қорыту екі модельдің тығыз құмды-қиыршықтасты жинауыштарда (Маху ойысының Байкоуцюань свитасы) литотиптерді ажыратуда өте жоғары дәлдік көрсететінін, ал XGBoost қалдық градиентті минимизациялау және жасырын заңдылықтарды анықтауда RF-тен жүйелі түрде асып түсетінін көрсетеді.

Практикалық қолдану нәтижелер ГИС деректерін автоматтандырылған түсіндіруге әдіснамалық негіз жасайды, мұнай-газ барлаудың эмпирикалық парадигмадан интеллектуалды басқаруға көшуіне ықпал етеді және машиналық оқытудың «қара жәшік» принципін ашуға көмектеседі.

ТҮЙІН СӨЗДЕР: *Жоңғар ойпаты, машиналық оқыту, Random Forest (RF), XGBoost алгоритмі, литологиялық классификация, ұңғымаларды геофизикалық зерттеу, ансамбльдік оқыту.*

APPLICATION OF MACHINE LEARNING ALGORITHMS FOR RESERVOIR LITHOLOGICAL CLASSIFICATION OF JUNGAR BASIN

N. TILEUBERDI, PhD, Associate Professor, *n.tileuberdi@satbayev.university*
CH. WEI, Doctoral Student, *2604637142@qq.com*

SATBAYEV UNIVERSITY
Republic of Kazakhstan, 050013, Almaty, Satbayev str., 22 a

This article provides a systematic review of the literature on the application of artificial intelligence (AI) to the lithological classification of deeply buried complex reservoirs, focusing on intelligent interpretation methods of well-logging data.

Main results obtained By integrating the multi-stage tectonic evolution characteristics of the Junggar Basin with data science logic, an interdisciplinary deconstruction of well-log datasets based on nine logging parameters was performed. For the first time, from the perspectives of mathematical mechanisms and geophysical responses, the classification performance and convergence of Random Forest (RF) and XGBoost algorithms were compared in complex nonlinear geological spaces. A synthesis of existing studies shows that both models demonstrate extremely high accuracy in differentiating lithotypes of tight sandy-gravel reservoirs (specifically, the Baikouquan Formation of the Mahu Depression), with XGBoost systematically outperforming RF in minimizing residual gradients and uncovering latent patterns.

Practical application the results provide a methodological foundation for automated well-log data interpretation, facilitate the transition of hydrocarbon exploration from an empirical paradigm to intelligent management, and help to reveal the "black box" mechanism of machine learning.

KEYWORDS: *Junggar Basin, machine learning, Random Forest (RF), XGBoost algorithm, lithological classification, well logging, ensemble learning.*

Введение. В связи с ростом мирового спроса на энергоресурсы и постепенным истощением запасов углеводородов в приповерхностных горизонтах нефтегазовая геологоразведка всё в большей степени ориентируется на изучение глубокозалегающих и сложнопостроенных резервуаров. Джунгарский бассейн является одним из крупнейших нефтегазоносных бассейнов Центральной Азии и характеризуется сложной тектонической эволюцией, развитой системой разломов и высокой литологической неоднородностью коллекторов [1]. В подобных геологических условиях эффективность традиционных методов интерпретации геолого-геофизических данных существенно снижается.

В последние годы стремительное накопление данных геофизических исследований скважин, сейсморазведки и геохимических наблюдений способствует активному внедрению технологий искусственного интеллекта в нефтегазовую отрасль. Методы машинного обучения позволяют обрабатывать большие объёмы многомерных данных, выявлять скрытые закономерности и повышать точность литологической интерпретации [2-3]. В связи с этим алгоритмы Random Forest, XGBoost, нейронные сети и другие методы искусственного интеллекта всё шире применяются при решении задач классификации пород, прогнозирования коллекторских свойств и оценки перспектив нефтегазоносности.

Особый интерес представляет применение технологий искусственного интеллекта для интерпретации каротажных данных в условиях сложнопостроенных песчано-гравийных коллекторов свиты Байкоуцюань во впадине Маху Джунгарского бассейна. Анализ опубликованных исследований показывает высокую эффективность ансамблевых алгоритмов машинного обучения при литологической идентификации подобных резервуаров.

В данной статье рассматриваются особенности геологического строения Джунгарского бассейна, современные подходы к применению искусственного интеллекта в нефтегазовой геологоразведке, а также анализируется опыт использования алгоритмов Random Forest и XGBoost для литологической классификации по данным геофизических исследований скважин.

Материалы и методы исследования

Геологические особенности Джунгарского бассейна

Джунгарский бассейн расположен в центральной части Центрально-Азиатского складчатого пояса, в зоне сочленения Сибирской, Казахстанской и Таримской платформ. Это ограниченная структура, сформировавшаяся в результате коллизии плит в позднем карбоне — ранней перми. Бассейн окружен палеозойскими складчатыми горными системами, включая палеозойские тектонические пояса: Алтайские горы на севере, горы Келамэйли на северо-востоке, Северный Тянь-Шань и Боро-Хоро на юге, а также горы Джаир, Хара-Арат и Делушань на северо-западе. Формирование Джунгарского бассейна контролировалось начальной тектоникой, связанной с коллизией Таримско-Центрально-Тяньшаньского массива и Северо-Тяньшаньско-Борохорской островной дуги. Мезозойско-кайнозойская эволюция бассейна в основном определялась воздействием процессов сопряжения гор и впадин, вызванных периодическими поднятиями окружающих орогенных поясов, а также отдаленными эффектами регионального орогенеза, что проявляется в наложении разновозрастных тектонических процессов и сложной многофакторной природе развития [4-5]. На основе анализа соответствующих геологических данных эволюцию бассейна можно разделить на четыре этапа:

1. Позднедевонский — раннекаменноугольный рифтогенный бассейн, в основном контролируемый рифтогенезом, с формированием каменноугольных материнских пород, распределенных вдоль рифтовых желобов;

2. Позднекаменноугольный — пермский коллизионный предгорный бассейн, подверженный влиянию столкновения плит и тектонических поднятий, что ограничило пермские материнские породы предгорными впадинами, такими как Маху, Чанцзи и Келамэйлишань;

3. Триасовый — палеогеновый внутриконтинентальный бассейн, характеризующийся чередованием впадин и осадочных систем, с широким распространением глин и углей в бассейне;

4. Неогеновый — четвертичный регенерированный (внутриконтинентальный субдукционный) предгорный бассейн, отражающий комплексное влияние внутриконтинентальной субдукции плит и процессов переформирования, развитый в основном в западной части южной окраины бассейна.

Весь процесс эволюции демонстрирует контроль взаимодействия гор и бассейнов, тектонического сжатия плит и многоэтапных наложенных преобразований на тектоническую и осадочную эволюцию бассейна. Его основные этапы тектонического развития и влияние на генерацию углеводородов подробно представлены в *таблице 1* [6].

Многоэтапная тектоническая эволюция эффективно сформировала благоприятные условия для накопления углеводородов в Джунгарском бассейне. На основе данных о геологическом строении бассейна, распределении нефтематеринских пород и корреляции нефть-источник, в Джунгарском бассейне можно выделить четыре сложных нефтегазоносных комплекса: каменноугольный, пермский, юрский и палеогеновый. Нефтематеринские породы каменноугольного комплекса представлены в основном керогеном типов II–III, с генерацией небольшого количества нефти на

Таблица 1 - **Основные этапы тектонической эволюции Джунгарского бассейна и их влияние на генерацию углеводородов**

Эволюционный этап	Геологический период	Тектоническая обстановка	Основные типы осадков	Влияние на нефтегазоносные системы
Рифтовый	Девон-карбон	Растяжени	Морские/болотные фации, глины, угли	Закладка карбоновых источников
Форландовый	Карбон- пермь	Сжатие	Озёрные/прибрежные песчано-глинистые породы	Формирование пермских источников
Прогибный	Триас- палеоген	Растяжение со сжатием	Озёрно-аллювиальные угленосные толщи	Активная генерация и миграция
Инверсионный	Неоген-четвертичный период	Сжатие	Красные песчано-конгломератовые породы	Перераспределение и повторная зарядка

раннем этапе, но в целом с преобладанием газогенерации. Их распространение в основном локализовано в районе Гуайшиси-Уцайвань в центральной части бассейна, образуя полосу широтного простирания, простирающуюся на юг до выступа Сантай на востоке. Пермский нефтегазоносный комплекс характеризуется нефтематеринскими породами преимущественно нефтегенерирующего типа с керогеном типов I–II, генерировавшими большое количество нефти на раннем этапе. На позднем этапе, под влиянием тектонической инверсии в гималайскую эпоху, глубина залегания значительно увеличилась, особенно в южной части Центральной впадины, что привело к быстрой генерации газа на поздней стадии. Пермский комплекс широко распространен на большей части территории, включая северо-западную окраину, центральную часть и южную окраину бассейна. Юрский нефтегазоносный комплекс в основном представлен угленосными и многопластовыми углистыми нефтематеринскими породами с керогеном типа III. На раннем этапе генерировалось небольшое количество нефти, а на позднем этапе преобладает значительная газогенерация. Он распространен главным образом в Центральной зоне поднятий и к югу от нее. Палеогеновый нефтегазоносный комплекс имеет относительно ограниченное распространение, ограничиваясь впадиной Сыкэсу в западной части южной окраины бассейна, и характеризуется локальным формированием залежей [7].

Таким образом, Джунгарский бассейн расположен в зоне сочленения трех крупных плит и подвержен влиянию многоэтапной коллизии, сопряжения гор и бассейнов, а также тектонического наложения. Пройдя четыре этапа сложной эволюции, он сформировал сложные нефтегазоносные комплексы в пространственно-временном распределении. Общая тектоническая обстановка и условия формирования залежей являются чрезвычайно сложными. Поэтому традиционные методы разведки уже не позволяют эффективно и точно идентифицировать местоположение залежей, а также выявить закономерности их распределения и ресурсный потенциал. Технологии искусственного интеллекта, благодаря интеграции разнородных данных, моделированию динамической эволюции и интеллектуальному прогнозированию зон обогащения углеводородов, предоставляют важную технологическую поддержку для нефтегазовой разведки в сложных бассейнах.

Идентификация литологии подземных отложений по данным геофизических исследований скважин (ГИС) является важнейшей задачей в нефтегазовой разведке

и разработке месторождений. В последние годы для решения задач литологического распознавания применяются различные вычислительные алгоритмы, позволяющие повысить точность прогнозирования. В данной главе на примере песчано-гравийных коллекторов свиты Байкоуцюань во впадине Маху демонстрируются результаты практического применения методов машинного обучения — случайного леса (Random Forest, RF) и алгоритма XGBoost — для идентификации литологии по данным ГИС [8].

Применение искусственного интеллекта в литологической классификации

В процессе разведки и разработки нефтегазовых месторождений точная идентификация подземных литологических типов имеет важное значение для оценки коллекторов и прогнозирования нефтегазоносности. Поскольку формирование и распределение залежей углеводородов во многом контролируются литологическими условиями, точность литологической классификации напрямую влияет на результаты геологического моделирования, выделения коллекторов и прогноза нефтегазоносности. Каротажные данные обладают такими преимуществами, как непрерывность, высокое разрешение и способность достоверно отражать изменения литологии в разрезе, благодаря чему они широко применяются в задачах литологической интерпретации. С быстрым развитием технологий искусственного интеллекта в нефтяной геологии всё больше исследователей используют методы машинного обучения для литологической классификации по данным геофизических исследований скважин. Современные исследования демонстрируют активное применение различных алгоритмов, включая Random Forest, XGBoost, нейронные сети, transfer learning, active learning и методы domain adaptation, для повышения точности интерпретации каротажных данных в сложных геологических условиях. В *таблице 2* представлены основные исследования последних лет, посвящённые применению искусственного интеллекта и каротажных данных для литологической классификации.

Таблица 2 - **Основные исследования последних лет по применению искусственного интеллекта**

Автор	Метод (AI)	Область применения	Основные преимущества	Ограничения
J H He et al (2016)	Cross plot (GR–DEN)	Идентификация сланцев	Эффективное разделение литологических типов и органообогащённых слоёв	Зависимость от опыта интерпретатора
R Y wang et al (2016)	Cross plot (GR–DEN–CNL)	Идентификация органообогащённых сланцев	Высокая чувствительность GR к органическим сланцам	Ограниченная универсальность
Liu Y et al. (2017)	Principal component analysis (PCA)	Идентификация аргиллитов	Учёт нескольких каротажных параметров одновременно	Зависимость от качества исходных данных
Mou D. et al (2015)	Support vector machine (SVM)	Идентификация вулканических пород	Эффективность при малых выборках	Ограниченная производительность для сложных резервуаров
Asante-Okyere et al. (2022)	Bayesian optimization tree models	Песчано-глинистые формации	Повышение точности за счёт оптимизации параметров	Зависимость от качества обучающих данных
Liang H. et al. (2022)	SA-SVM	Идентификация аргиллитов и известняков	Высокая точность классификации	Ограниченная интерпретируемость

Таблица 2 - **Основные исследования последних лет по применению искусственного интеллекта**

Автор	Метод (AI)	Область применения	Основные преимущества	Ограничения
P Wang et al. (2020)	HMM-Random Forest	Литологическая классификация	Улучшенная обработка перекрывающихся классов	Сложность настройки
A Singh et al. (2020)	Semi-supervised neural network	Газогидратные резервуары	Эффективная работа с большими объёмами данных	Неопределённость числа литологических классов
Gu Y et al. (2021)	CRBM -PSO - XGBoost	Литологическая классификация	Автоматическая оптимизация гиперпараметров	Ограниченное число моделей для сравнения
Ren Q et al. (2022)	Fuzzy ID3 decision tree	Прогнозирование литологии	Снижение переобучения и повышение точности	Эмпирическая настройка гиперпараметров
Li Z et al. (2020)	Semi-supervised learning - K-means	Классификация редких литологических классов	Использование немаркированных данных	Недостаточное обоснование выбора K-means
J Chang et al. (2021)	Two-stream neural network	Адаптация домена	Снижение деградации производительности модели	Эффективность только при малых различиях доменов
H Liu et al. (2020)	Transfer learning - AELM	Идентификация литологии новых скважин	Повышение точности переноса модели	Отсутствие абляционного анализа
L Zhu et al. (2018)	Wavelet analysis- CNN	Глубокое обучение по ГИС	Преобразование 1D-кривых в 2D-изображения	Эвристический характер CNN
Y Xie et al. (2020)	LOF - Extremely Randomized Trees	Литологическая классификация	Очистка аномальных данных и повышение точности	Высокая вычислительная сложность
Xiang et al. (2020)	Deep belief network (DBN)	Анизотропные резервуары	Эффективная работа со сложными зависимостями	Требуются большие объёмы данных
Zhang X L et al. (2023)	CNN	Непрерывные песчано-глинистые разрезы	Эффективное выделение нескольких литотипов	Риск переобучения при недостатке данных

В последние годы для решения задач литологической классификации в нефтегазовой геологоразведке широко применяются различные методы машинного обучения. Среди наиболее распространённых алгоритмов особое место занимают Random Forest (RF) и XGBoost, которые отличаются высокой устойчивостью к шумам, способностью эффективно работать с многомерными данными и высокой точностью классификации при интерпретации каротажных материалов [9-15].

Алгоритм Random Forest представляет собой ансамблевый метод машинного обучения, основанный на построении множества деревьев решений и объединении их результатов. Благодаря случайному выбору обучающих выборок и признаков данный метод характеризуется высокой устойчивостью к переобучению и широко применяется для обработки сложных геолого-геофизических данных [9–12]. Алгоритм XGBoost относится к методам градиентного бустинга и обеспечивает последовательную оптимизацию модели за счёт минимизации ошибок предыдущих этапов обучения. Данный алгоритм отличается высокой вычислительной эффективностью

и способностью выявлять сложные нелинейные зависимости в многопараметрических данных [12–16].

В опубликованных исследованиях, посвящённых литологической классификации песчано-гравийных коллекторов свиты Байкоуцюань во впадине Маху Джунгарского бассейна, использовались данные геофизических исследований скважин (ГИС), полученные по 17 соседним скважинам. Как показано на *рисунке 1*, исследуемый район расположен во впадине Маху — одном из наиболее перспективных нефтегазоносных районов Джунгарского бассейна Северо-Западного Китая. Набор данных включал 9 видов каротажных параметров и результаты литологической интерпретации керновых изображений общей протяжённостью около 520 м. На основе проведённой интерпретации было сформировано 4156 точек данных, использованных для анализа возможностей алгоритмов машинного обучения [8].

В качестве входных параметров применялись естественная гамма-активность (GR), потенциал самопроизвольной поляризации (SP), кавернометрия (CALI), кажущееся удельное сопротивление мелкого, среднего и глубокого зондирования (RESS, RESM, RESD), нейтронная пористость (PHIN), объемная плотность (RHOB), а также интервальное время пробега продольной волны (DT) (*таблица 3*). Согласно результатам интерпретации керновых изображений, в отложениях свиты Байкоуцюань были выделены три основные литофации: аргиллиты, песчаники и песчано-гравийные породы. Сформированный набор данных включал прогнозные параметры и целевую переменную — литологический класс [8].

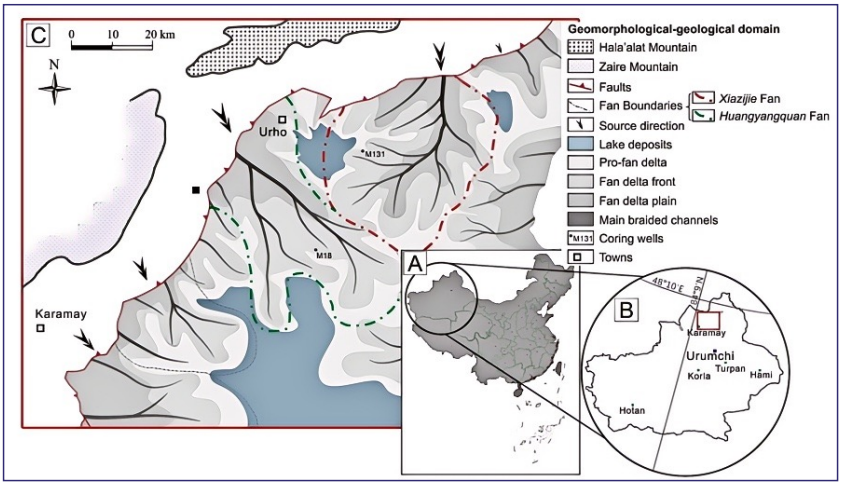

Рисунок 1 - **Расположение района исследований /7/.** *(A) Обзорная карта провинции Синьцзян, Китай. (B) Район работ на севере Синьцзянской провинции. (C) Детальная карта с указанием типичных местоположений скважин с отбором керна и приблизительных границ древних конусов выноса (включая пролювиальные конусы и конусы выноса дельт).*

Таблица 3 - **Описание данных геофизических исследований скважин (ГИС)**

STATISTICS	DEPTH	GR	SP	CALI	RESS	RESM	RESD	PHIN	PHOB	DT
MEAN	3820.63	55.44	–1.02	8.72	20.54	24.51	23.53	19.28	2.50	72.52
STD	157.30	13.83	33.97	0.77	17.42	15.15	15.78	4.77	0.10	6.76
MIN	3279.63	29.29	–68.06	5.59	0.20	2.88	–1.69	9.01	1.85	58.31
50%	3855.13	52.32	–9.53	8.50	16.48	22.14	20.92	18.21	2.52	70.52
MAX	4350.25	109.375	102.36	16.82	126.39	114.34	104.93	47.40	2.68	118.61

В рамках рассматриваемого исследования авторами были построены ROC-кривые на основе тестового подмножества данных (*рисунок 2*). Глубокий анализ механизмов распознавания литотипов различными интеллектуальными алгоритмами показал, что классификаторы, обученные на многомерных признаках, ГИС, обладают исключительно высокой дискриминационной способностью и достоверностью при расчленении разреза плотных коллекторов. С позиций геолого-геофизического отклика, аргиллиты, обладающие выраженными и специфическими радиоактивными и электрическими реперными свойствами, продемонстрировали максимальные значения площади под ROC-кривой (AUC) в обеих моделях, достигнув 0,97 для XGBoost и 0,96 для Random Forest. Напротив, идентификация смешанных песчаников оказалась более трудоемкой задачей ввиду перекрытия петрофизических свойств, вызванного размытостью седиментационных границ. Тем не менее, показатель AUC для данного литотипа стабильно превышает 0,92, что свидетельствует о высокой робастности моделей извлечения данных при работе со слабодифференцированными границами. Для целевых песчано-гравийных коллекторов значения AUC заняли промежуточное положение, варьируя в диапазоне 0,94–0,95.

Результаты и обсуждение

Преимущества и перспективы применения искусственного интеллекта. Технологии искусственного интеллекта (ИИ), основанные на анализе данных, транс-

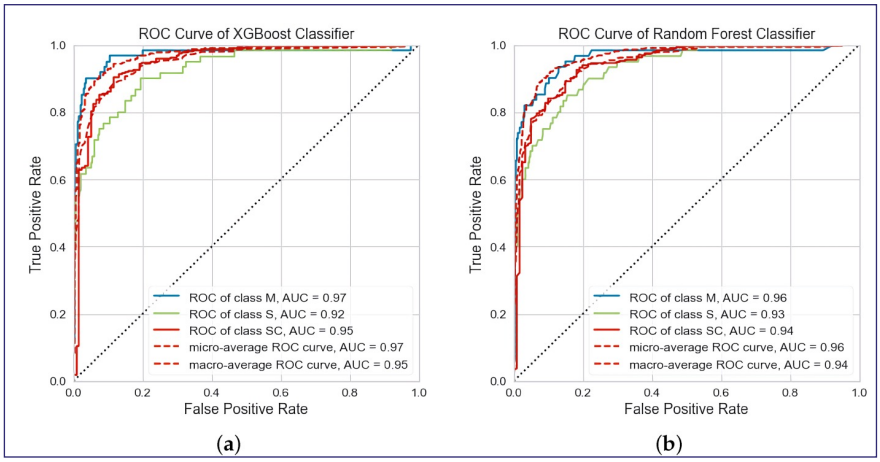

Рисунок 2 - **ROC-кривые для алгоритмов XGBoost (a) и случайного леса (RF) (b). M — аргиллит, S — песчаник, SC — песчано-гравийные породы**

формируют традиционную парадигму разведки и разработки нефтегазовых месторождений, обеспечивая переход от эмпирического подхода («парадигмы, основанной на опыте») к интеллектуальному управлению [14, 15]. Внедрение подходов Data Science позволяет осуществлять сквозную автоматизацию процессов и интегрировать гетерогенные данные из различных источников, что критически важно для работы в сложных геологических условиях. Для количественной оценки эффективности внедрения интеллектуальных подходов был проведен сравнительный анализ ИИ-методов и традиционных детерминистических подходов (*таблица 4*).

Таблица 4 - **Сравнительный анализ эффективности традиционных методов и методов ИИ**

Критерий сравнения	Методы искусственного интеллекта (ИИ)	Традиционный метод
Базовый принцип	Данные-ориентированный подход, автоматическое аппроксимирование нелинейных зависимостей	Модельно-ориентированный подход на основе физических законов и эмпирического опыта
Интеграция данных	Комплексный анализ разнородных (гетерогенных) данных из различных источников	Работа преимущественно с однородными выборками данных
Выделение признаков	Автоматическое извлечение значимых информативных признаков алгоритмическими методами	Ручное выделение признаков экспертом на основе петрофизических зависимостей
Уровень автоматизации	Сквозная автоматизация сквозных процессов обработки информации	Поэтапное ручное управление и пошаговый контроль
Производительность	Высокопроизводительное пакетное прогнозирование в режиме реального времени на базе обученной модели	Длительная последовательная ручная интерпретация данных
Экономическая эффективность	Значительные первоначальные инвестиции при низких долгосрочных операционных затратах	Низкие разовые затраты при экспоненциально растущих трудозатратах

Аналитическая интерпретация результатов сравнения показывает, что ключевое преимущество ИИ заключается в переходе от последовательной ручной обработки к высокопроизводительному пакетному прогнозированию. Это позволяет нивелировать проблему «информационных островков» и систематизировать разрозненные геолого-геофизические данные. Перспективными направлениями развития интеллектуальных систем в нефтегазовой отрасли являются глубокая междисциплинарная интеграция алгоритмов машинного обучения с фундаментальной геологией, внедрение графов знаний для формализации экспертного опыта, а также разработка адаптивных, интерпретируемых (XAI) моделей, способных стабильно функционировать в условиях жесткого дефицита обучающих выборок [16-18].

Заключение и выводы

Системный вызов геологической среды. На примере Джунгарского бассейна (впадины Маху) наглядно прослеживается общая тенденция усложнения условий поиска углеводородов. Многоэтапная тектоника, латеральная изменчивость фаций и высокая анизотропия песчано-гравийных коллекторов свиты Байкоуцюань формируют комплексы с высокой энтропией данных. Это делает традиционные детерминистические подходы интерпретации каротажных данных недостаточно эффективными и диктует необходимость смены технологической парадигмы.

Аналитическая оценка потенциала ансамблевых алгоритмов. Проведенный в статье систематический анализ отечественного и зарубежного опыта подтверждает, что ансамблевые методы машинного обучения (в частности, Random Forest и XGBoost) на сегодняшний день представляют собой наиболее перспективный аналитический инструмент для литологического расчленения сложных разрезов. Обладая высокой устойчивостью к шумам и способностью улавливать скрытые нелинейные зависимости, данные алгоритмы позволяют автоматизировать идентификацию продуктивных горизонтов, минимизируя субъективный фактор экспертных ошибок.

Критические барьеры текущего этапа. В ходе дескриптивного анализа выявлено, что широкомасштабное промышленное внедрение интеллектуальных систем в нефтегазовую геофизику по-прежнему сдерживается тремя фундаментальными барьерами: проблемой «черного ящика» (низкой интерпретируемостью моделей для геологов-практиков), дефицитом качественных стандартизированных обучающих выборок и феноменом «информационных островков» в управлении данными.

Вектор будущих технологических трендов. На основе обобщения существующих тенденций можно утверждать, что эволюция интеллектуализации нефтегазовой разведки будет лежать в плоскости междисциплинарного синтеза. Ключевыми драйверами отрасли в среднесрочной перспективе станут развитие объяснимого искусственного интеллекта (XAI), внедрение гибридных моделей, сочетающих Data Science с фундаментальными законами петрофизики, и построение отраслевых графов знаний. Реализация этих направлений критически важна для обеспечения рентабельной разведки глубокозалегающих и нетрадиционных резервуаров.

ЛИТЕРАТУРА

1. Ван Ю., Цзя Д., Пань Ц. и др. Многоэтапное тектоническое наложение и переработка в Джунгарском бассейне Северо-Западного Китая: значение для разведки глубокозалегающих углеводородов // AAPG Bulletin. – 2018. – Т. 102, № 8. – С. 1489–1521. [Wang Y., Jia D., Pan J., et al. multi-stage tectonic overprinting and reworking in the Junggar Basin, Northwest China: Implications for deep hydrocarbon exploration // AAPG Bulletin. – 2018. – Vol. 102, No. 8. – P. 1489–1521.]
2. Чэнь Ц., Чжан Г., Ху М. и др. Исследование идентификации магматических пород на основе модели SE-AttenTransNet: пример зоны разлома Хунчэ в Джунгарском бассейне // Arabian Journal for Science and Engineering. – 2025. – С. 1–18. [Chen Q., Zhang G., Hu M., et al. Research on Magmatic Rock Identification Based on SE-AttenTransNet Model: A Case Study of Hongche Fault Zone in Junggar Basin // Arabian Journal for Science and Engineering. – 2025. – P. 1–18.]

3. Чжэн Ч., Чжан Л., Чэн М. и др. Литологическая идентификация сильно неоднородных глубокопогруженных коллекторов по данным каротажа на основе улучшенной байесовской инверсии: нижнеюрские песчаники центральной части Джунгарского бассейна, Китай // Frontiers in Earth Science. – 2023. – Т. 11. – 1095611. [Zheng C., Zhang L., Cheng M., et al. Lithology identification of highly heterogeneous deep-buried reservoirs based on logging data using improved Bayesian inversion: Lower Jurassic sandstones in central Junggar Basin, China // Frontiers in Earth Science. – 2023. – Vol. 11. – 1095611.]

4. Хэ Дэнфа, Чжан Лэй, У Сунтао и др. Этапы тектонической эволюции Джунгарского бассейна и их характеристики // Геология нефти и газа. – 2018. – С.845-861. [He Dengfa, Zhang Lei, Wu Songtao, et al. Stages of Tectonic Evolution of the Junggar Basin and Their Characteristics // Oil and Gas Geology. – 2018. – P. 845–861.]

5. Ван Яньцзюнь. Роль многоэтапной тектоники в контроле формирования залежей и разведка глубоких углеводородов в Джунгарском бассейне // Нанкинский университет. – 2020. – С.185-198. [Wang Yanjun. The Role of Multi-Stage Tectonics in Controlling Deposit Formation and Deep Hydrocarbon Exploration in the Junggar Basin // Nanjing University. – 2020. – P. 185–198.]

6. Чэнь Ецюань, Ван Вэйфэн. Тектоническая эволюция и характеристики формирования нефтегазовых залежей в Джунгарском бассейне // Журнал Университета нефти (Естественнонаучное издание).– 2020. – С.185-198. [Chen Yequan, Wang Weifeng. Tectonic Evolution and Characteristics of Oil and Gas Accumulation in the Junggar Basin // Journal of the University of Petroleum (Natural Science Edition). – 2020. – P. 185–198.]

7. Цзян Шаньюй, Тэн Хуэй, Ван Цзинь и др. Размышления о трансформации разведки и разработки нефти и газа, движимой искусственным интеллектом // Экономика природных ресурсов Китая. – 2026. – С.1-11. [Jiang Shanyu, Teng Hui, Wang Jin, et al. Reflections on the Transformation of Oil and Gas Exploration and Development Driven by Artificial Intelligence // Natural Resource Economics of China. – 2026. – P. 1–11.]

8. Чжан Ц., Хэ Ю., Чжан Ю., Ли В., Чжан Ц. Классификация литологии по данным геофизических исследований скважин с использованием методов машинного обучения для идентификации высококачественных коллекторов на примере свиты Байкоуцюань в районе Маху Джунгарского бассейна (Северо-Западный Китай) // Energies. – 2022. – Т. 15, № 10. – 3675. – DOI: 10.3390/en15103675. [Zhang Q., He Y., Zhang Y., Li W., Zhang C. Lithology Classification Using Well-Logging Data with Machine Learning Methods for High-Quality Reservoir Identification: A Case Study of the Baikouquan Formation in the Mahu Area, Junggar Basin (Northwest China) // Energies. – 2022. – Vol. 15, No. 10. – 3675. – DOI: 10.3390/en15103675.]

9. Лу С., Сунь Д., Се С., Чэнь С., Чжан С., Чжан С., Сунь Г., Ши Ц. Характеристики микрофаций и нефтегазовый потенциал триасовой свиты Байкоуцюань на севере впадины Маху, Джунгарский бассейн, Северо-Западный Китай // Journal of Natural Gas Geoscience. – 2019. – Т. 4. – С. 47–62. [Lu X., Sun D., Xie X., Chen X., Zhang S., Zhang S., Sun G., Shi J. Microfacies characteristics and hydrocarbon potential of the Triassic Baikouquan Formation in the northern Mahu Sag, Junggar Basin, Northwest China // Journal of Natural Gas Geoscience. – 2019. – Vol. 4. – P. 47–62.]

10. Тао Ц., Чжан Ц., Цюй Ц., Юй С., Чжу Р. Метод de-flat roundness для количественной характеристики формы частиц // Arabian Journal of Geosciences. – 2018. – Т. 15. – 414. [Tao Q., Zhang J., Qu J., Yu S., Zhu R. The de-flat roundness method for quantitative characterization of particle shape // Arabian Journal of Geosciences. – 2018. – Vol. 15. – 414.]

11. Лю Х., У Ю., Цао Ю., Люй В., Хань Х., Ли Ц., Чан Ц. Построение модели идентификации литологии по данным каротажа в условиях дрейфа данных: метод трансферного обучения // Sensors. – 2020. – Т. 20. – 3643. [Liu H., Wu Y., Cao Y., Lü W., Han X., Li Q., Chang Q. Construction of Logging Lithology Identification Model under Data Drift Conditions: A Transfer Learning Method // Sensors. – 2020. – Vol. 20. – 3643.]
12. Брессан Т.С., Кель де Соуза М., Джирелли Т.Дж., Жуниор Ф.К. Оценка методов машинного обучения для классификации литологии с использованием геофизических данных // Computers & Geosciences. – 2020. – Т. 139. – 104475. [Bressan T.S., Kehl de Souza M., Girelli T.J., Junior F.C. Evaluation of machine learning methods for lithology classification using geophysical data // Computers & Geosciences. – 2020. – Vol. 139. – 104475.]
13. Сингх Х., Сеол Ю., Мышакин Э.М. Автоматизированная обработка каротажных данных и классификация литологии путем определения оптимальных признаков с помощью алгоритмов машинного обучения без учителя и с учителем // SPE Journal. – 2020. – Т. 25, № 5. – С. 2778–2800. [Singh H., Seol Y., Myshakin E.M. Automated Well-Log Processing and Lithology Classification by Identifying Optimal Features Through Unsupervised and Supervised Machine-Learning Algorithms // SPE Journal. – 2020. – Vol. 25, No. 5. – P. 2778–2800.]
14. Доу Хунэнь, Чжан Лэй, Ми Лань и др. Текущее состояние применения и перспективы искусственного интеллекта в мировой нефтегазовой промышленности // Нефтяное и газовое бурение и добыча. – 2021(4). – С.405-419. [Dou Hongen, Zhang Lei, Mi Lan, et al. Current Application Status and Prospects of Artificial Intelligence in the Global Oil and Gas Industry // Oil and Gas Drilling and Production. – 2021(4). – P. 405–419.]
15. Чжу Билань, Цао Фань, Ли Кунь и др. Перспективы применения искусственного интеллекта в области разведки глубоких нефтегазовых горизонтов // Инновации в науке и технике и применение. – 2025. – С.12-16. [Zhu Bilan, Cao Fan, Li Kun, et al. Prospects for the Application of Artificial Intelligence in the Field of Deep Oil and Gas Exploration // Innovations in Science and Technology and Their Application. – 2025. – P. 12–16.]
16. Тянь Мэнде. Применение технологий анализа искусственного интеллекта в нефтепромысловом производстве // Китайская научно-техническая информация. – 2025. –С.53-55. [Tian Mengdie. Application of Artificial Intelligence Analysis Technologies in Oilfield Production // China Science and Technology Information. – 2025. – P. 53–55.]
17. Бин Шаоцян. Практика и размышления о применении технологий искусственного интеллекта в управлении нефтепромысловым производством // Нефтехимические технологии. – 2020. – С.118-119. [Bing Shaoqiang. Practice and Reflections on the Application of Artificial Intelligence Technologies in Oilfield Production Management // Petrochemical Technologies. – 2020. – P. 118–119.]
18. Чэнь Яньчжэ. Возможности, вызовы и предложения для нового поколения искусственного интеллекта в области нефтегазовой разведки // Форум по нефтяным технологиям. – 2025. – С.67-75. [Chen Yanzhe. Opportunities, Challenges, and Proposals for the New Generation of Artificial Intelligence in the Field of Oil and Gas Exploration // Oil Technology Forum. – 2025. – P. 67–75.]