

Вестник Евразийской науки / The Eurasian Scientific Journal <https://esj.today>

2026, Том 18, № 2 / 2026, Vol. 18, Iss. 2 <https://esj.today/issue-2-2026.html>

URL статьи: <https://esj.today/PDF/14NZVN226.pdf>

2.8.4. Разработка и эксплуатация нефтяных и газовых месторождений (технические науки)

Ссылка для цитирования этой статьи:

Иванчук, Е. А. Эволюция концепции Smart Fields: систематический анализ применения методов машинного обучения в нефтегазовой отрасли и барьеров их масштабирования / Е. А. Иванчук, Е. В. Егорова, В. С. Агафонов // Вестник евразийской науки. — 2026. — Т. 18. — № 2. — URL: <https://esj.today/PDF/14NZVN226.pdf>.

For citation:

Ivanchuk E.A., Egorova E.V., Agafonov V.S. The evolution of the Smart Fields concept: a systematic analysis of the application of machine learning methods in the oil and gas industry and the barriers to their scaling. *The Eurasian Scientific Journal*. 2026;18(2): 14NZVN226. Available at: <https://esj.today/PDF/14NZVN226.pdf>. (In Russ., abstract in Eng.).

УДК 004.89

Иванчук Евгений Артемович

ФГБОУ ВО «Астраханский государственный технический университет», Астрахань, Россия

E-mail: olgaiva@atgmu.ru

ORCID: <https://orcid.org/0009-0007-3947-4982>

Егорова Елена Валерьевна

ФГБОУ ВО «Астраханский государственный технический университет», Астрахань, Россия

Заведующий кафедрой «Разработки и эксплуатации нефтяных и газовых месторождений»

Кандидат технических наук, доцент

E-mail: olgaiva@atgmu.ru

ORCID: <https://orcid.org/0000-0002-8424-8980>

Агафонов Вадим Сергеевич

ФГБОУ ВО «Астраханский государственный технический университет», Астрахань, Россия

E-mail: agafonovenator@gmail.com

ORCID: <https://orcid.org/0009-0005-3214-3721>

**Эволюция концепции Smart Fields:
систематический анализ применения методов
машинного обучения в нефтегазовой отрасли и
барьеров их масштабирования**

Аннотация. Нефтегазовая отрасль, столкнувшись с истощением легкодоступных запасов, волатильностью цен и ужесточением экологических требований, переживает фундаментальную трансформацию, драйвером которой выступает концепция «умного месторождения» (Smart Field) и технологии искусственного интеллекта (ИИ). Несмотря на доказанную эффективность пилотных проектов, широкомасштабное внедрение ИИ сдерживается системными барьерами, что обуславливает необходимость их комплексного анализа. Цель исследования состояла в проведении систематического анализа применения методов машинного обучения в нефтегазовой отрасли для выявления ключевых барьеров внедрения и наиболее перспективных направлений развития Smart Fields. Анализ публикационной активности за 2015–2025 гг. подтвердил устойчивый рост интереса к теме (среднегодовой темп +15 %). Классифицированы основные задачи ИИ: интерпретация сейсмике и прогноз свойств коллекторов, управление добычей (прогнозирование отказов, обучение с подкреплением, виртуальные расходомеры), обеспечение целостности активов (RBI на основе ИИ,

мультимодальная аналитика коррозии). Выявлены четыре группы барьеров: качество и изолированность данных («data isolation»), инфраструктурные ограничения, организационно-кадровые вызовы, а также недостаточная интерпретируемость моделей. Интерпретированы ключевые тренды: переход от точечной автоматизации к цифровым двойникам, от описательной аналитики к предписывающей, эволюция бизнес-моделей в сторону ко-инноваций и интеграция целей устойчивого развития. Обобщение результатов позволило сформулировать вывод: отрасль переходит от фазы «романтизации» ИИ к прагматичной инструментализации. Наиболее перспективными направлениями признаны гибридные архитектуры, объединяющие data-driven подходы с физическими моделями, развитие объяснимого искусственного интеллекта для повышения доверия к системам, а также создание мультиагентных систем с централизованной оркестрацией. Успех масштабирования ИИ будет определяться способностью компаний преодолевать организационные и культурные барьеры, инвестировать в развитие кросс-дисциплинарных компетенций и выстраивать эффективные партнерства.

Ключевые слова: нефтегазовая отрасль; Smart Fields; цифровая трансформация; искусственный интеллект; машинное обучение

Введение

Нефтегазовая отрасль, являясь фундаментом мировой энергетической безопасности, в настоящее время переживает период фундаментальных изменений. Во-первых, снижение цен на углеводороды, истощение легкодоступных запасов («легкой нефти»), рост требований к экологической ответственности и последствия глобальных кризисов вынуждают компании искать новые пути повышения операционной эффективности и устойчивости. Во-вторых, четвертая промышленная революция, «Индустрия 4.0», как ключевой драйвер трансформирует отрасль в сторону применения цифровых технологий. Искусственный интеллект (ИИ), машинное обучение, Интернет вещей (IoT), прогнозная аналитика и цифровые платформы позволяют улучшать качества обслуживания клиентов, обеспечивать гибкость, внедрять более совершенные операционные модели и эффективно управлять цепочками поставок, усиливая конкурентные преимущества [1; 2]. «Данные цифровые решения помогут операторам нефтегазовой отрасли найти новые методы для реализации своих планов по повышению производительности, прогнозируемому техническому обслуживанию и расширению оперативной информации, что приведет к последовательному, повторяемому и более быстрому принятию решений» [1; с. 36].

Данные вызовы послужили драйвером для применения технологии искусственного интеллекта в нефтегазовой отрасли, так впервые зародилась концепция Smart Field [3; 4], которая позволила бы решить проблемы уменьшения добычи на действующих месторождениях, разработки новых трудноизвлекаемых месторождений, находящихся в сложных геологических условиях. Очевидно, что реализации данной концепции потребует внедрения новых управленческих подходов [5], направленных не столько только на автоматизацию бизнес-процессов, сколько на переход к комплексным интегрированному управлению в реальном времени [6].

Концепция Smart Field базируется на создании интегрированной модели месторождения, объединяющей геологическую модель пласта и модель наземной инфраструктуры, ключевыми компонентами которой являются «умные скважины» (Smart Wells), оснащенные постоянными датчиками температуры и давления, а также управляемыми с поверхности клапанами для регулирования притока, что позволяет вести одновременно-раздельную эксплуатацию и бороться с обводнением. Поверхностная инфраструктура объединяется системами телемеханики и промышленного интернета вещей (IIoT), передающими огромные массивы данных в центры управления [7]. Важнейшим аспектом становится и интеллектуальное управление энергоснабжением,

позволяющее оптимизировать потребление электроэнергии насосным оборудованием, которое может достигать 30 % экономии [8].

Первая «умная» скважина была построена еще в 1997 году на месторождении Snorre в Северном море, а к середине 2000-х годов ведущие мировые компании, такие как Shell (Smart Field), BP (Field of the Future) и Chevron (i-field), начали масштабное внедрение этих технологий [9]. Знаковым примером успешной реализации концепции в России стал проект компании «Салым Петролеум Девелопмент» (СПД) — совместного предприятия Shell и «Газпром нефти», в рамках которого удалось оборудовать системами удаленного мониторинга и управления 100 % своего фонда скважин [10]. Результаты впечатляют: время отклика при выходе скважины на режим сократилось с двух суток до одного часа, коэффициент эксплуатационной готовности достиг 97 %, а наработка на отказ электроцентробежных насосов (ЭЦН) выросла с 500 до 750 суток. При этом количество выездов персонала на скважины сократилось с 40 до 7–8 в месяц, а добыча увеличилась в среднем на 2–2,5 % в год [10]. Анализ современных научных работ демонстрирует экспоненциальный рост интереса к применению методов машинного обучения в нефтегазовом секторе. В своем большинстве, исследователи едины в мнении о значительном потенциале ИИ в области оптимизации и планирования разработки скважин [9], применения его в целях создания прогностических моделей добычи, переработки [11], обеспечения безопасности на различных участках [8].

Однако, несмотря на впечатляющий потенциал и доказанную эффективность пилотных проектов, практическое внедрение ИИ и концепции Smart Field в целом сталкивается с рядом системных проблем. Глубокое исследование опыта государственной нефтяной компании ADNOC (ОАЭ), проведенное группой исследователей из Австралии и Саудовской Аравии, выявило не только позитивные эффекты от внедрения ИИ, но и ключевые барьеры: проблемы интеграции с устаревшими системами, вопросы кибербезопасности, дефицит квалифицированных кадров и высокие первоначальные затраты [12]. Данные выводы коррелируют с результатами опросов, представленных в рамках диссертационного исследования Л. Келси Престиджа, в котором установлено, что главными препятствиями внедрения концепции Smart Field является корпоративная культура и сопротивление изменениям, а также сложность интеграции с существующей инфраструктурой [1]. Говоря о мнении российских экспертов наблюдается единство во мнении о наличии специфических российских трудностях: недостаточное развитие инфраструктуры связи на удаленных месторождениях и консерватизм отрасли, предпочитающей сначала оценивать зарубежный опыт [13].

Таким образом, анализ литературы выявляет противоречие: с одной стороны, существует обширный пласт исследований и успешных кейсов, доказывающих высокую эффективность ИИ и концепции Smart Field для решения конкретных производственных задач. С другой стороны, остро ощущается нехватка систематизированных работ, обобщающих накопленный опыт и анализирующих именно проблемы и барьеры широкомасштабного внедрения этих технологий в операционную деятельность вертикально-интегрированных нефтегазовых компаний. Большинство обзоров фокусируется на технических аспектах, оставляя за рамками организационные, кадровые и стратегические вызовы, которые являются определяющими для успеха [9].

В связи с этим, настоящее исследование является, на наш взгляд, актуальным, так как оно направлено на заполнение данного пробела. Цель работы — провести систематический анализ современного состояния применения методов ИИ/МО в нефтегазовой отрасли для выявления ключевых барьеров внедрения и наиболее перспективных направлений развития, а именно ответить на вопросы: (1) какие методы машинного обучения наиболее часто применяются в контексте Smart Fields и для решения каких задач? (2) каковы основные технологические и организационные барьеры, препятствующие масштабированию ИИ-решений?

(3) какие перспективные направления (архитектуры, методы) определяют ближайшее будущее развития отрасли?

Материалы и методы

Для реализации поставленной цели мы воспользовались рекомендациями PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), представленные Д. Моером и его коллегами [15]. Для оценки масштабов и динамики исследований на стыке искусственного интеллекта (ИИ) и нефтегазовой отрасли был проведен анализ доступных литературных источников. В качестве основных платформ для поиска были определены крупнейшие научные библиотеки и базы данных: ScienceDirect (издательство Elsevier), предоставляющая доступ к тысячам рецензируемых журналов и книг по физическим и инженерным наукам; российская научная электронная библиотека КиберЛенинка, построенная на принципах открытой науки (Open Access) и аккумулирующая статьи из журналов, в том числе входящих в перечень ВАК РФ; а также специализированные отраслевые издания, такие как научно–производственный журнал «Автоматизация и IT в нефтегазовой области», который целенаправленно освещает вопросы внедрения цифровых технологий в нефтегазовом комплексе. Поиск осуществлялся по ключевым словам: Smart Field, digital oil field, artificial intelligence, machine learning, asset integrity management, predictive analytics, neural networks и их комбинации на русском и английском языках.

Аналізу подверглись полнотекстовые рецензируемые статьи в журналах (ВАК, Scopus/WoS), материалы конференций SPE за последние 10 лет (2015–2025 гг), обзоры, кейсы с количественными результатами. Нами был использован метод синтеза данных: нарративный синтез (тематический анализ) с элементами контент-анализа для классификации проблем и методов.

Основная часть

Анализ научно-исследовательской литературы позволил получить ряд, на наш взгляд, интересных выводов, от описания общей характеристики публикаций по данной проблемной области до выявления трендов и направлений развития ИИ в нефтегазовой сфере. Раскроем последовательно полученные результаты.

1. Общая характеристика потока публикаций. Анализ публикационной активности показывает устойчивый рост интереса к теме применения методов машинного обучения в нефтегазовой отрасли. Авторы отмечают, что с бурным развитием технологий искусственного интеллекта и ростом спроса на интеллектуализацию в нефтегазовой индустрии, такие методы, как глубокое обучение, стали широко применяться в различных областях — от геологоразведки до добычи и производства [15]. Согласно библиометрическому исследованию Эджийи, Ч. Дж., Цай Д., Томас Д. и др., в базе Scopus за период 2010–2024 гг. было идентифицировано 11 296 статей, соответствующих тематике ИИ в нефтегазовой отрасли [16], включающие в себя как общие работы по ИИ, так и специализированные прикладные исследования. Анализ временной динамики, проведенный авторами, показывает, что среднегодовой темп роста числа публикаций в этой области составляет около 15 % [2]. В период активного внедрения технологии глубоких нейронных сетей в решение инженерных задач различного типа, приходящийся примерно на 2018–2020 гг., наблюдался значительный рост публикации в области применения данных технологий в нефтегазовой отрасли.

Регионами-лидерами по количеству публикаций являются США (в своем большинстве работы касаются вопросов применения МО для сланцевых проектов), Китай (работы авторов

сконцентрированы вокруг применения глубоких нейронных сетей в задачах прогнозирования и интерпретации геофизических данных) [16], Норвегия и Великобритания (применении МО для разработки месторождений Северного моря), Бразилия (применение ИИ для разработки глубоководных месторождений), а также страны Ближнего Востока [1]. Говоря о российском сегменте публикаций по данной проблемной области, необходимо отметить, что публикации в своем большинстве раскрывают реализацию практических кейсов внедрения ИИ и адаптацию уже имеющегося опыта зарубежных коллег.

Анализ публикационной активности авторов позволил выделить группу наиболее цитируемых исследователей: К.Дж. Эджийи, Д. Цай, Д. Томас систематизирующие задачи применения ИИ в нефтегазовой отрасли [17]; К. Ван, Ю. Ли, Р. Ли разрабатывающие нейросетевые архитектуры и гибридные алгоритмы прогнозирования добычи и оптимизации процессов добычи [18]; З. Садеки-Арани, А.А. Кадходайе, решающие вопросы безопасности путем внедрения ИИ для предупреждения аварий прогнозирования отказов оборудования и оценку рисков [19]; Кричинский А.К., Поспеев А.В., использующие ИИ для учета неоднородности данных (статических и динамических) [20] и др.

Обобщая вышесказанное, можно говорить об ИИ в нефтегазовой отрасли как о динамично развивающейся научной области знаний и практики. Широкий спектр задач, описанный в исследованиях авторов охватывает вопросы интеграции ИИ как технического плана, так и организационно-управленческого

2. Классификация задач и методов машинного обучения. Анализ современной литературы позволяет систематизировать применение методов машинного обучения (МО) в нефтегазовой отрасли по ключевым направлениям производственного цикла. Во-первых, рассматривается применение методов МО для решения задач геологического моделирования и управления добычей, которые, как правило, требуют значительных трудозатрат. Алгоритмы МО позволяют автоматизировать интерпретацию геолого-геофизических данных, повышая точность полученных результатов и минимизируя влияние человеческого фактора. Так, в работах Р. Чжан, М.К. Сен, С. Шринивасан и М.И. Шимелевич описывается применение сверточных нейронных сетей (CNN) для интерпретации изображений сейсмических срезов и разломов, которые позволили обеспечить прогнозирование коллекторских свойств при условии низкой субъективности [21; 22]. Кроме того, CNN нашли свое применение для визуального контроля и классификации коррозии трубопроводов как решение задачи контроля целостности инфраструктуры [24]. Данные подходы формируются в настоящее время в отдельное направление исследований. Связанных с анализом CNN фотографий или микротомографических снимков как цифровых двойников керна как высокоточные цифровые модели пласта.

Такие методы МО как глубокие нейронные сети находят свое применение в для анализа пористости, проницаемости и выявления нелинейных зависимостей различного рода геофизических данных скважин. Примером использования глубокой нейронной сети (DNN) с долгосрочной памятью является разработка Ц. Ван, Ц. Цао, Ш. Юань, направленная на решение задач прогнозирования пористости коллектора. Полученная авторами модель достигла коэффициента детерминации выше 0,95, подтверждая свою эффективность по сравнению с традиционной линейной регрессией. Кроме того, авторами отмечается сокращение времени расчетов более чем на 90 %, что говорит о высоком потенциале DNN для достоверного и оперативного анализа запасов.

Во-вторых, методы МО находят свое применение в области добычи, решая проблемы повышения коэффициента извлечения нефти (КИН), снижение операционных затрат и предотвращение аварийных ситуаций. Так, применение алгоритмов многослойного перцептрона (MLP) и метода опорных векторов (SVM) для прогнозирования отказов центробежных насосов, обученных на реальных эксплуатационных данных, достигли высоких показателей точности

(F1-score > 0.89), что позволяет своевременно выявлять потенциальные неисправности и предотвращать внеплановые остановки производства [25].

Решая проблемы динамики многомерных систем, с которыми не справляются классические методы оптимизации, активно развиваются подходы, основанные на обучении с подкреплением (Reinforcement Learning, RL). К сожалению, мы не обнаружили академических публикаций на русском языке по этой тематике, но мировой опыт, представленный в Google Scholar, демонстрирует успешное применение RL для автоматического подбора параметров работы скважин и системы заводнения в реальном времени с целью максимизации накопленной добычи [26]. Данные методы позволяют ИИ-агенту самостоятельно обучаться оптимальной стратегии управления на основе обратной связи от промышленных данных.

Кроме того, можно выделить ряд работ, в которых раскрывается успешное внедрение, так называемых, виртуальных расходомеров, построенных на базе нейросетей как альтернативный подход для оценки дебита нефти, газа и воды на основе легкодоступных технологических параметров (давление, температура, состояние насоса). Исследование, проведенное группой исследователей Китайского университета нефти, представляет собой пример такой системы раннего предупреждения, где LSTM-модель, интегрирующая как динамические показатели работы скважины, так и статические геологические параметры, позволяет не только прогнозировать будущую обводненность, но и косвенно оценивать изменения в добыче [16]. Подобные подходы описаны в работах, проиндексированных в базе данных ScienceDirect. Используемые для исследований валидированные промышленные данные подтверждают надежность и экономическую эффективность LSTM-модели.

Таким образом, описанные выше примеры демонстрируют, на наш взгляд, возможности МО для комплексного управления месторождениями, до управления в реальном времени.

Третьим направлением применения МО является решения задач обеспечения безопасности на всех уровнях добычи и производства. Анализ работ авторов позволил выделить несколько подходов, направленных на продление жизненного цикла и повышение экономической составляющей:

Первый подход направлен на обеспечение управляемости целостностью активов. Традиционные подходы, основанные на планово-предупредительных ремонтах, уступают место интеллектуальным системам, способным прогнозировать развитие дефектов. Классическая методология Risk-Based Inspection (RBI) предполагает расстановку приоритетов инспекций на основе анализа рисков. Интеграция методов машинного обучения позволяет перейти от статических оценок к динамическим, постоянно обновляя профили риска на основе поступающих данных. Как отмечается в диссертационной работе М.М. Аль-Мазруи, посвященной трансформации ADNOC, внедрение ИИ для прогнозной аналитики технического обслуживания, позволило компании не только сократить незапланированные простои, но и повысить общую надежность активов. Система, использующая алгоритмы машинного обучения и цифровые двойники, способна прогнозировать отказы оборудования, что напрямую влияет на безопасность и эффективность операций [27].

В рамках решения задач предиктивной аналитики коррозии методы МО предполагают интеграцию разнородных данных (Multi-Modal AI), включая результаты магнитного контроля, данные о химическом составе среды, режимах эксплуатации и результаты визуальных инспекций. Например, А. Ходаяри-Ростамабад, Дж.П. Рейли, Н.К. Николова еще 2009 году одними из первых применили методы машинного обучения (включая регрессию на опорных векторах) для анализа изображений магнитного потока рассеяния (MFL) с целью более точной классификации и оценки глубины дефектов [28]. Разработанная 2020 году гибридная модель, позволяющая объединить регрессию опорных векторов, аналитику главных компонент и оптимизацию роем частиц, позволила построить прогностическую модель скорости внутренней коррозии трубопровода с высокой точностью (ошибка всего 0,112) [29].

Второй подход направлен на решения ряда задач разработки месторождений, а именно их моделирования и оптимизации. Как правило, для этого необходимы значительные объемы данных и, как следствие, огромные вычислительные мощности. Применение технологии ИИ обучение с подкреплением позволило осуществлять расчеты, учитывающие одновременно перераспределение объемов закачки между нагнетательными скважинами и «выравнивание» фронта вытеснения. Данные подходы были реализованы описаны, например, в работах А. Нвачукву, Х. Чон, М. Пирц, Л.В. Лейк, которые разработали прокси-модель на основе МО для быстрого поиска оптимальных вариантов размещения скважин при заводнении [30]. Данный подход позволили авторам сократить вычислительные затраты по сравнению с традиционным моделированием. Кроме того, современные исследования направлены на автоматизацию настройки гидродинамической модели на фактическую историю разработки с помощью методов МО, например, гибридная система, сочетающая оптимизацию роением частиц с нейронными сетями для ускорения калибровки модели в условиях геологической неопределенности [6]. Такой подход позволяет существенно сократить время, требуемое для получения адекватной модели, и повысить точность прогнозов добычи.

Таким образом, методы ИИ трансформируют как подходы к обеспечению безопасности, так и к управлению разработкой активов. Прогнозирование коррозии и автоматизация калибровки моделей позволяют не только снижать риски, но и принимать более обоснованные решения, ведущие к увеличению КИН.

3. Проблемы и барьеры внедрения ИИ. Анализ научно-исследовательской литературы позволил нам выявить ряд системных барьеров на фоне значительного потенциала и растущего числа успешных пилотных проектов, широкомасштабного внедрения технологии ИИ в операционную деятельность нефтегазовых компаний.

Барьер 1. Качество и доступность данных. Данный барьер характерен не только для нефтегазовой отрасли, однако и здесь является ключевым. Качественные, репрезентативные и размеченные данные являются одним из важнейших условий разработки эффективной модели ИИ. Как отмечается рядом авторов, данные хранятся разрозненно и принадлежат разным бизнес-компаниям и подразделениям и зачастую составляют коммерческую тайну [13]. Так, например, Д. Цзя, Дж. Чжан, Ю. Ли, Л. Ву, М. Цяо отмечают остроту проблемы данных в целом, и для решения проблем управления заводнением в частности [31].

Обсуждая главный тезис «шум на входе – шум на выходе», ряд авторов подчёркивает проблему неполноты данных, наличия ошибок в измерениях и разметки. Поэтому для разработки моделей ИИ, направленных на решение задач прогнозирования обводненности с целью минимизации влияния качества данных требует тщательной предобработки (фильтрацию, удаление пропусков и повторов, отбор признаков) [16]. Говоря об обучении моделей с учителем, отмечается необходимость разметки данных экспертами, например, для распознавания типов коррозии, классификации дефектов, что является трудоемким и дорогостоящим процессом и, как следствие, сдерживающим фактором [28].

Барьер 2. Инфраструктурные ограничения внедрения ИИ в нефтегазовую отрасль. Данный барьер возникает в связи с противоречием между новыми технологиями и устоявшимися традиционными бизнес-процессами. Новые технологии, как правило, являются несовместимыми с действующими системами. Например, проблема централизованного анализа данных в реальном времени, возникающая по причине невозможности оперативной передачи массивов данных, требует развитие периферийных вычислений, т. е. модернизации ИТ-инфраструктуры, связанной с отказом использования передачи данных через спутник и созданием высокопроизводительных центров вычислений [1].

В совокупности создание и модернизация всей необходимой ИТ-инфраструктуры — центров обработки данных, высокопроизводительных вычислений и лицензионного программного обеспечения — требуют столь значительных капиталовложений, что становятся труднореализуемой задачей, особенно в периоды низких цен на углеводороды.

Барьер 3. Организационные и кадровые барьеры. Организационно-кадровые вызовы признаны критическим барьером, зачастую превосходящим по сложности технические аспекты. Первостепенной проблемой является острый дефицит специалистов, обладающих кросс-дисциплинарными компетенциями на стыке нефтегазового дела и Data Science, что усугубляется недостаточной «цифровой грамотностью» даже на уровне высшего руководства [13 и др.]. Не менее серьезным препятствием выступает организационная культура и сопротивление персонала, которое может проявляться как в страхе перед заменой ИИ, так и в недоверии к неинтерпретируемым («черным ящикам») моделям, что делает управление изменениями и вовлечение сотрудников необходимым условием успеха [31 и др.].

Данные проблемы напрямую приводят к феномену «пилотного ада»: компании успешно демонстрируют эффективность ИИ в отдельных проектах, но оказываются неспособны масштабировать эти решения. Причинами служат отсутствие стандартизации, сложность интеграции с уникальными особенностями каждого актива и неготовность операционных подразделений менять устоявшиеся процессы, что в совокупности нивелирует потенциальные выгоды от внедрения новых технологий [25].

Барьер 4. Надежность, интерпретируемость и валидация моделей. Методологические ограничения моделей машинного обучения формируют третий ключевой барьер, связанный с доверием к результатам их работы, то есть возникает общая для всех областей применимости ИИ проблема «черного ящика». Данная проблема заключается в недоверии ИИ в связи с непониманием логики получения конечного результата. С одной стороны, системы ИИ демонстрируют высокую точность, с другой стороны, — стимулируют необходимость разработки объяснимого ИИ [17; 18]. Нельзя не отметить сложность валидации моделей в условиях геологической неопределенности. Как правило, модели, обученные на исторических данных, могут не учесть реальные данные, характеризующие режим эксплуатации скважины и свойства пласта [5; 10], что акцентирует внимание на проблеме обеспечения надежности прогнозов и их интерпретируемости.

4. Ключевые тренды развития ИИ в нефтегазовой отрасли. Результатом проведенного нами систематического обзора является выделенные тренды (траектории) развития ИИ в нефтегазовой отрасли.

Тренд 1. Переход от точечной автоматизации к цифровым двойникам как переход от отдельных «умных» компонентов к разработке цифровых экосистем — цифровой двойник месторождений [5; 32]. Так, например, ведущая норвежская нефтегазовая компания «Equinor» в Северной Европе перешла от изолированных инициатив по внедрению ИИ в создание специализированной цифровой экосистемы «Центра передового опыта в области цифровизации» (Digital Center of Excellence), аккумулирующего все направления деятельности, от бурения и добычи до управленческих решений[1]. Данный тренд также подтверждается и кейсом государственной нефтегазовой компанией Объединенных Арабских Эмиратов ADNOC (Abu Dhabi National Oil Company), в деятельность которой внедрена прогнозная аналитика на базе ИИ как часть корпоративной стратегии [27].

Тренд 2. Переход к прогностическим моделям отказа как переход от мониторинга к прогнозированию будущих состояний и разработке управленческих решений [6; 21].

Тренд 3. Преодоление барьеров как новые направления развития ИИ. Как нами было описано ранее, проблема «черного ящика» является и для нефтегазовой области ключевой

проблемой, поэтому ее преодоление является еще одним направлением развития исследований в области ИИ в нефтегазовой отрасли. Недоверие инженеров к результату работы ИИ стимулирует разработку объяснимого ИИ. Кроме того, решение проблем с данными подталкивает исследователей к разработке методов, основанных на физических законах, с целью их масштабирования с одного месторождения на другое [29].

Тренд 4. Эволюция бизнес-моделей и партнерств. Цифровая трансформация меняет ландшафт взаимоотношений между игроками рынка, наблюдается переход от простых закупок услуг к стратегическим партнерствам и совместным предприятиям с ведущими технологическими компаниями (Baker Hughes, H&P, Nabors) для совместного развития инноваций. Такая модель взаимодействия — модель ко-инновации (co-innovation) позволяет распределять риски и объединять компетенции для создания технологий будущего.

Параллельно обостряется вопрос о праве собственности на данные. По мере того как данные становятся ключевым активом, размышления о том, кому принадлежат данные, генерируемые на скважине — оператору, буровому подрядчику или сервисной компании, — становятся предметом сложных контрактных переговоров и могут определять конкурентные преимущества в будущем [14].

Тренд 5. Интеграция целей устойчивого развития. Применение ИИ все чаще рассматривается не только как инструмент повышения прибыли, но и как средство достижения экологических целей. В работах Б.Б. Окогбе, Э.К. Ндубуиси, Э. Оморогиува подчеркивается, что оптимизация процессов бурения и добычи с помощью ИИ ведет к снижению энергопотребления, уменьшению выбросов парниковых газов и минимизации воздействия на окружающую среду [7]. Прогнозирование коррозии помогает предотвращать разливы, а оптимизация заводнения — сокращать объемы добываемой и закачиваемой воды. Таким образом, ИИ становится ключевым фактором в реализации стратегий Environmental, Social, Governance в отрасли.

В целом, ключевые тренды свидетельствуют о переходе нефтегазовой отрасли в новую фазу цифровой зрелости. Успех больше не определяется наличием отдельных цифровых продуктов, а зависит от способности компаний интегрировать их в единую экосистему, преодолевать организационные и культурные барьеры, развивать новые формы партнерств и использовать ИИ для достижения не только экономических, но и экологических целей. Неравномерность этого перехода (разрыв между лидерами и отстающими) будет определять конкурентный ландшафт отрасли в ближайшее десятилетие.

Заключение

Анализ современных тенденций и выявленных барьеров позволяет сформулировать ряд перспективных направлений, которые будут определять развитие искусственного интеллекта в нефтегазовой отрасли в ближайшие годы. Перспективное направление 1. Гибридные архитектуры и цифровые двойники. Будущее принадлежит не просто «черным ящикам» машинного обучения, а гибридным моделям, интегрирующим data-driven подходы с фундаментальными физическими законами. Создание прокси-моделей на основе нейросетей, способных замедлять полномасштабные гидродинамические симуляторы, уже стало реальностью [31]. Следующий шаг — создание полномасштабных цифровых двойников месторождений, объединяющих в реальном времени геологическую модель, модель наземной инфраструктуры и экономическую модель актива. Работа исследователей Харбинского технологического института, интегрирующая динамические и статические геологические параметры для прогноза обводненности, является ярким примером движения в этом направлении [16]. Prestidge подчеркивает, что такие двойники станут основой для принятия стратегических решений и позволят перейти к проактивному управлению активами на протяжении всего жизненного цикла [23].

Перспективное направление 2. Объяснимый искусственный интеллект (Explainable AI — XAI). Преодоление недоверия со стороны инженеров и геологов к «черным ящикам» является критическим условием для широкого внедрения ИИ. Именно поэтому в настоящее время наблюдается рост числа публикаций, описывающих возможности разработки и внедрения XAI, в том числе и в нефтегазовую отрасль.

Перспективное направление 3. Разработка мультиагентных ИИ-систем, позволяющих решать взаимосвязано несколько задач в рамках концепции ко-инновации. Каждый ИИ-агент такой системы, решает свою задачу, будь то задачи оптимизации, прогнозирования отказов и оценки рисков, однако их взаимосвязь позволяет найти комплексное решение, формируя цифровую экосистему[3].

Таким образом, проведенный анализ позволяет сформулировать следующие выводы, отражающие авторскую позицию относительно современного состояния и перспектив внедрения искусственного интеллекта в нефтегазовой отрасли. Во-первых, на наш взгляд, ключевой вывод заключается в том, что отрасль завершила этап романтизации искусственного интеллекта и перешла к фазе прагматичной инструментализации. Сегодняшний ландшафт исследований, от прогнозирования коррозии с использованием гибридных моделей до создания систем раннего предупреждения обводненности, демонстрирует зрелый инженерный подход. ИИ становится таким же инструментом, как гидродинамический симулятор, но требующим точной настройки, качественных входных данных и, главное, понимания его физических и математических основ. Успех измеряется не количеством внедренных пилотов, а способностью компаний масштабировать решения, преодолевая инфраструктурные и организационные барьеры, которые зачастую сложнее технических.

В-вторых, можно говорить о неизбежной трансформации роли специалиста (инженера, администратора, айтишника, геолога), работающего в нефтегазовой отрасли. Вопреки распространенным опасениям, ИИ не заменяет геологов и инженеров, но кардинально меняет структуру их работы, смещая фокус с рутинных операций на стратегические задачи. Цифровые двойники берут на себя мониторинг и прогнозирование, освобождая время для анализа нестандартных ситуаций и принятия решений в условиях неопределенности. Однако, данный переход требует осознанных усилий со стороны компаний: инвестиций в развитие цифровых компетенций, формирования культуры работы с данными и доверия к интеллектуальным системам. В конечном счете, будущее нефтегазовой отрасли будет определяться не столько совершенством алгоритмов, сколько способностью отраслевого сообщества воспитать новое поколение специалистов, для которых работа на стыке физики пласта и Data Science станет естественной профессиональной средой.

ЛИТЕРАТУРА

1. Prestidge, K.L. Digital Transformation in the Oil and Gas Industry: Challenges and Potential Solutions (Master's thesis). Massachusetts Institute of Technology. — 2021. — 138 p. Режим доступа: <https://dspace.mit.edu/handle/1721.1/143178> (дата обращения: 19.11.2025).
2. Póvoas M.d.S., Moreira J.F., Neto S.V.M., Carvalho C.A.d.S., Cezario B.S., Guedes A.L., Lima G.B.A. Artificial Intelligence in the Oil and Gas Industry: Applications, Challenges, and Future Directions // Applied Sciences. — 2025. — № 15(14). — e7918. Режим доступа: <https://doi.org/10.3390/app15147918> (дата обращения: 26.12.2025).

3. Philbeck T., Davis N. The fourth industrial revolution: shaping a new era // Journal of International Affairs. — 2018. — vol. 72. — no. 1. — pp. 17–22. Режим доступа: <https://www.scirp.org/reference/referencespapers?referenceid=4107640> (дата обращения: 19.11.2025)
4. Соловенко И.С., Рожков А.А. Основные этапы цифрового перехода в топливно-энергетическом комплексе России (рубеж XX–XXI вв.) // Уголь. — 2023. — № 10. — С. 72–78. Режим доступа: <http://dx.doi.org/10.18796/0041-5790-2023-10-72-78> (дата обращения: 03.01.2026).
5. Линник Ю.Н., Кирюхин М.А. Цифровые технологии в нефтегазовом комплексе// Вестник университета. — 2019. — № 7. — pp. 37–40. Режим доступа: <https://vestnik.guu.ru/jour/article/view/1601/848> (дата обращения: 03.01.2026).
6. Ucar A., Karakose M., Kırımca N. Artificial intelligence for predictive maintenance applications: key components, trustworthiness, and future trends //Applied Sciences. — 2024. — Т. 14. — № 2. — С. 898. Режим доступа: <https://elibrary.ru/item.asp?id=66154105> (дата обращения: 03.01.2026).
7. Okogbe B.B., Ndubuisi E.C., Omorogiuwa E. Digital technology adoption, sustainability, and well construction delivery in oil and gas industry: Critical review of digital technology // International Journal of Science and Research Archive. — 2025. — 15(02) — pp. 1366–1380. Режим доступа: <https://doi.org/10.30574/ijstra.2025.15.2.1487> (дата обращения: 09.01.2026).
8. Alshehhi O. The Role of Artificial Intelligence in Driving Change Management in the UAE Public Sector. International Journal of Technology and Systems. — 2025. — № 10(3). — pp. 32–44. Режим доступа: <https://doi.org/10.47604/ijts.3479> (дата обращения: 19.01.2026).
9. Haouel C., Nemeslaki A. Digital Transformation in Oil and Gas Industry: Opportunities and Challenges // Periodica Polytechnica Social and Management Sciences. — 2024. — № 32(1). — pp. 1–16. Режим доступа: <https://doi.org/10.3311/PPso.20830> (дата обращения: 02.02.2026).
10. Шустер М.Ю., Бондарь М.Ю., Карпан В.М., Кольцов И.Н. Результаты пилотного проекта АСП компании «Салым Петролеум Девелопмент» // Недропользование XXI век. — 2018. — № 4(74). — С. 170–187. — Режим доступа: <https://elibrary.ru/item.asp?id=35490679> (дата обращения: 06.12.2025).
11. Волокин Я.Е., Шустер М.Ю., Кольцов И.Н., Чмуж И.В. Внедрение технологии АСП: Пилотный проект// Недропользование XXI век. 2015 № 11. С. 14–122. Режим доступа: https://nedra21.ru/upload/iblock/4e7/v3pknzauels6obwsk7z7vclrpduukr3i/114_121.pdf (дата обращения: 06.12.2025).
12. Hussain M. et al. Application of artificial intelligence in the oil and gas industry // Engineering applications of artificial intelligence. — Cham: Springer Nature Switzerland, 2024. — С. 341–373. Режим доступа: https://www.researchgate.net/publication/375999766_Application_of_Artificial_Intelligence_in_the_Oil_and_Gas_Industry (дата обращения: 06.12.2025).
13. Bist N., Panchal S., Gupta R., Soni A., Sircar A. Digital transformation and trends for tapping connectivity in the oil and gas sector // Hybrid Advances — 2024. — vol. 6. — e100256 Режим доступа: <https://doi.org/10.1016/j.hybadv.2024.100256> (дата обращения: 21.12.2025).

14. Ionova S.V. Smart Technologies in the Humanitarian Field: The Needs for Practice and the Possibilities of Implementation // Smart technologies for society, state and economy. — Volgograd: Springe. — 2021. — pp. 769–776. Режим доступа: https://doi.org/10.1007/978-3-030-59126-7_85 (дата обращения: 19.11.2025).
15. Moher D., Liberati A., Tetzlaff J., Altman D.G. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement // BMJ. — 2009. — 339. — e2535. Режим доступа: <https://doi.org/10.1136/bmj.b2535> (дата обращения: 06.12.2025).
16. Li J., Zhang C., Lin Y., Liu Y., Jin Q., Xiao T., Liu X., Zhang Y. An early warning system for oil wells based on improved long short-term memory network // Frontiers in Earth Science. — 2025. — № 12. — e1508776. Режим доступа: <https://www.frontiersin.org/journals/earth-science/articles/10.3389/feart.2024.1508776/full> (дата обращения: 01.03.2026).
17. Ejiyi C.J., Cai D., Thomas D. et al. Comprehensive review of artificial intelligence applications in renewable energy systems: current implementations and emerging trends // J Big Data. — 2025. — № 12. — pp. 169. Режим доступа: <https://doi.org/10.1186/s40537-025-01178-7> (дата обращения: 19.11.2025).
18. Wang Q., Li Y., Li R. Integrating artificial intelligence in energy transition: A comprehensive review // Energy Strategy Reviews. — 2025. — vol. 57. — e101600. Режим доступа: <https://www.sciencedirect.com/science/article/pii/S2211467X24003092> (дата обращения: 24.01.2026).
19. Sadeqi-Arani Z., Kadkhodaie A. A bibliometric analysis of the application of machine learning methods in the petroleum industry // Results in Engineering. — 2023. — vol. 20. — pp. 101518. Режим доступа: <https://www.sciencedirect.com/science/article/pii/S259012302300645X> (дата обращения: 19.11.2025).
20. Кричинский А.К., Поспеев А.В. Интеграция искусственного интеллекта в обработку геолого-геофизических данных при разведке твердых полезных ископаемых // Науки о Земле и недропользование. — 2025. — Т. 48. — № 3(92). — С. 310–320. Режим доступа: <https://www.nznj.ru/jour/article/view/422/0> (дата обращения: 14.12.2025).
21. Zhang R., Sen M.K., Srinivasan S. A prestack basis pursuit seismic inversion // Geophysics. — 2013. — vol. 12. — № 1. — pp. 618–627. Режим доступа: <https://link.springer.com/article/10.1007/s12182-015-0056-3> (дата обращения: 19.11.2025).
22. Шимелевич М.И. Применение методов искусственного интеллекта (нейронных сетей) в обратных нелинейных задачах геофизики с приложением к геоэлектрике // Марчуковские научные чтения. — 2022. — Режим доступа: <https://cyberleninka.ru/article/n/primenenie-metodov-iskusstvennogo-intellekta-neyronnyh-setey-v-obratnyh-nelineynyh-zadachah-geofiziki-s-prilozheniem-k-geoelektrike> (дата обращения: 10.01.2026).
23. Wang J., Cao J., Yuan S. Deep learning reservoir porosity prediction method based on a spatiotemporal convolution bi-directional long short-term memory neural network model // Geomechanics for Energy and the Environment. — 2022. — vol. 32. — e100282. Режим доступа: <https://www.sciencedirect.com/science/article/abs/pii/S2352380821000496> (дата обращения: 09.13.2026).

24. Bastian B.T., Jaspreeth N., Ranjith S.K., Jiji C.V. Visual inspection and characterization of external corrosion in pipelines using deep neural network // NDT & E International. — 2019. — vol. 107. — e102134. Режим доступа: <https://www.sciencedirect.com/science/article/abs/pii/S096386951930060X?via%3Dihub> (дата обращения: 03.13.2026).
25. Orru P.F., Zoccheddu A., Sassu L., Mattia C., Cozza R., Arena, S. Machine Learning Approach Using MLP and SVM Algorithms for the Fault Prediction of a Centrifugal Pump in the Oil and Gas// Industry. Sustainability. — 2020. — no. 12(11). — e4776. Режим доступа: <https://www.scirp.org/reference/referencespapers?referenceid=3043483> (дата обращения: 03.13.2026).
26. Bismukhametov T., Jäschke J. First principles and machine learning virtual flow metering: a literature review // Journal of Petroleum Science and Engineering. — 2020. — no. 184. — e106487. Режим доступа: <https://www.sciencedirect.com/science/article/pii/S0920410519309088> (дата обращения: 03.13.2026).
27. Al-Mazrouei M.M. The role of Artificial Intelligence in Transforming the Operations of the Abu Dhabi National Oil Company: University of Central Lancashire. — 2025. — 228 p. Режим доступа: https://knowledge.lancashire.ac.uk/id/eprint/56191/1/Almazrouei%2CMaktoom_PhD_ThesisSubmission_20250228.pdf (дата обращения: 26.01.2026).
28. Khodayari-Rostamabad, A., Reilly, J.P., Nikolova, N.K., Hare, J.R., & Pasha, S. (2009). Machine learning techniques for the analysis of magnetic flux leakage images in pipeline inspection // IEEE Transactions on Magnetics. — 2009. no. 45(10). — pp. 3073–3084. Режим доступа: https://www.researchgate.net/profile/James-Reilly-20/publication/224565531_Machine_Learning_Techniques_for_the_Analysis_of_Magnetic_Flux_Leakage_Images_in_Pipeline_Inspection/links/004635260105cae5c7000000/Machine-Learning-Techniques-for-the-Analysis-of-Magnetic-Flux-Leakage-Images-in-Pipeline-Inspection.pdf (дата обращения: 11.11.2025).
29. Peng S., Zhang Z., Liu,E., Liu W., Qiao W. A new hybrid algorithm model for prediction of internal corrosion rate of multiphase pipeline // Journal of Natural Gas Science and Engineering. 2020. — no. 85. — e103716. Режим доступа: <https://doi.org/10.1016/j.jngse.2020.103716>. (дата обращения: 07.12.2026).
30. Nwachukwu A., Jeong H., Pyrcz M., Lake L.W. Fast evaluation of well placements in heterogeneous reservoir models using machine learning // Journal of Petroleum Science and Engineering. — 2028. — 163. — pp. 463–475. Режим доступа: <https://doi.org/10.1016/j.petrol.2018.01.019> (дата обращения: 19.11.2025).
31. Jia D., Zhang J., Li Y., Wu L., Qiao M. Recent Development of Smart Field Deployment for Mature Waterflood Reservoirs. Sustainability. — 2023. — № 15(1). — pp. 784. Режим доступа: https://www.mdpi.com/2071-1050/15/1/784?utm_source=researchgate.net&utm_medium=article (дата обращения: 11.11.2025).

Ivanchuk Evgeny Artemovich

Astrakhan State Technical University, Astrakhan, Russia
E-mail: olgaiva@atgmu.ru
ORCID: <https://orcid.org/0009-0007-3947-4982>

Egorova Elena Valerievna

Astrakhan State Technical University, Astrakhan, Russia
E-mail: olgaiva@atgmu.ru
ORCID: <https://orcid.org/0000-0002-8424-8980>

Agafonov Vadim Sergeevich

Astrakhan State Technical University, Astrakhan, Russia
E-mail: agafonovenator@gmail.com
ORCID: <https://orcid.org/0009-0005-3214-3721>

The evolution of the Smart Fields concept: a systematic analysis of the application of machine learning methods in the oil and gas industry and the barriers to their scaling

Abstract. The oil and gas industry, faced with depletion of readily available reserves, price volatility and stricter environmental requirements, is undergoing a fundamental transformation driven by the concept of a «smart field» and artificial intelligence (AI) technology. Despite the proven effectiveness of pilot projects, the large-scale implementation of AI is hampered by systemic barriers, which necessitates their comprehensive analysis. The purpose of the study was to conduct a systematic analysis of the use of machine learning methods in the oil and gas industry to identify key barriers to implementation and the most promising areas of Smart Fields development. An analysis of publication activity in 2015–2025 confirmed a steady increase in interest in the topic (an average annual rate of +15 %). The main tasks of AI are classified: seismic interpretation and reservoir property prediction (CNN, LSTM), mining management (failure prediction, reinforcement learning, virtual flow meters), asset integrity assurance (AI-based RBI, multimodal corrosion analytics). Four groups of barriers have been identified: data quality and isolation («data isolation»), infrastructural constraints, organizational and personnel challenges, and insufficient interpretability of models. The key trends are interpreted: the transition from point automation to digital twins, from descriptive to prescriptive analytics, the evolution of business models towards co-innovation and the integration of sustainable development goals. Summarizing the results allowed us to formulate a conclusion: the industry is moving from the phase of «romanticization» of AI to pragmatic instrumentalization. Hybrid architectures combining data-driven approaches with physical models, the development of explicable artificial intelligence to increase trust in systems, and the creation of multi-agent systems with centralized orchestration are recognized as the most promising areas. The success of AI scaling will be determined by companies' ability to overcome organizational and cultural barriers, invest in cross-disciplinary competencies, and build effective partnerships.

Keywords: oil and gas industry; Smart Fields; digital transformation; artificial intelligence; machine learning