

УДК 330.341.1

Гусейнов Давид Намирович

Санкт-Петербургский политехнический университет Петра Великого

Сидоров Илья Викторович

Санкт-Петербургский политехнический университет Петра Великого

Тельпиз Георгий Александрович

Санкт-Петербургский политехнический университет Петра Великого

**Баланс барреля: как генеративный ИИ меняет экономику геологоразведки и вводит
«зеленый» налог на вычисления**

Аннотация. В работе рассматривается двойственное влияние искусственного интеллекта на нефтегазовую отрасль. С одной стороны, внедрение нейросетевых методов интерпретации сейсмических данных, цифровых двойников пластов и систем предиктивной диагностики оборудования позволяет существенно сократить операционные и капитальные затраты. Реальные кейсы демонстрируют повышение успешности разведочного бурения до 67%, снижение незапланированных простоев на 18-30% и дополнительный прирост добычи на зрелых месторождениях до 2,3%. С другой стороны, обучение и эксплуатация крупных генеративных моделей и геологических фундаментальных моделей требуют колоссального энергопотребления – до десятков гигаватт-часов на одну модель, что сопоставимо с годовым потреблением сотен домохозяйств. В нефтедобывающих регионах, таких как ХМАО, ИИ-инфраструктура вступает в конкуренцию за энергомощности с основным производством, а использование попутного газа для питания вычислительных узлов не решает, а усугубляет экологическую проблему.

Ключевые слова: искусственный интеллект, энергопотребление, дата-центр, предиктивная диагностика, газ.

Guseynov David Namikovich

Peter the Great St. Petersburg Polytechnic University

Sidorov Ilya Viktorovich

Peter the Great St. Petersburg Polytechnic University

Telpiz Georgy Alexandrovich

Peter the Great St. Petersburg Polytechnic University

**The barrel balance: how generative AI transforms exploration economics and introduces a
Green Tax on computing**

Abstract. This paper examines the dual impact of artificial intelligence on the oil and gas industry. On the one hand, the implementation of neural network methods for seismic data interpretation, reservoir digital twins, and predictive diagnostic systems can significantly reduce operating and capital costs. Real-world cases demonstrate an increase in exploration drilling success rates to 67%, a reduction in unplanned downtime by 18-30%, and an additional production gain of up to 2,3% at mature fields. On the other hand, training and operating large generative models and geoscience foundation models require enormous energy consumption – up to tens of gigawatt-hours per single model, which is comparable to the annual electricity consumption of hundreds of households. In oil-producing regions such as Khanty-Mansiysk Autonomous Okrug, AI infrastructure competes with core production for power capacity, while using associated petroleum gas to power computing units does not solve but rather exacerbates the environmental problem.

Keywords: artificial intelligence, energy consumption, data center, predictive diagnostics, gas.

Традиционная геологоразведка сопряжена с принципиально высокой неопределённостью, и цена ошибки в ней чрезвычайно велика. По данным Международного энергетического агентства (МЭА), стоимость бурения разведочной скважины на суше в зависимости от глубины и региона составляет от 2 до 10 млн долл. США, в офшорном сегменте – от 30 до 150 млн долл. [1]. При этом средняя успешность разведочного бурения (доля скважин, подтвердивших коммерческие запасы) исторически не превышает 30-40%, а на ряде рискованных блоков падает ниже 20% [2]. Таким образом, каждое инвестиционное решение о начале бурения несёт вероятный убыток, который в случае «сухой» скважины полностью списывается как капитальные затраты.

Традиционный процесс интерпретации сейсмических данных трёхмерной (3D) съёмки требует от группы геофизиков от нескольких недель до 3-6 месяцев работы на одну площадь. Специалисты вручную отслеживают горизонты, идентифицируют разломы, строят структурные карты и оценивают литологические фации. Интерпретация зависит от квалификации и субъективных суждений эксперта, что вносит значительную вариабельность в оценку ресурсного потенциала.

Принципиальный технологический сдвиг начался с применения свёрточных нейронных сетей (CNN) для автоматической сегментации сейсмических кубов – задачи, аналогичной распознаванию изображений в компьютерном зрении. Обученные на размеченных сейсмических данных модели способны в режиме близком к реальному времени классифицировать отражающие горизонты, разломы и соляные купола с точностью, сопоставимой с экспертной, – но на три-четыре порядка быстрее.

Компания SLB (Schlumberger) в 2022-2024 годах внедрила платформу Delfi, интегрирующую CNN-модели интерпретации сейсмике с крупными языковыми моделями для генерации геологических отчётов и гипотез о строении пласта [3]. Согласно опубликованным компанией данным, время цикла интерпретации для типичного 3D-куба сократилось с 12-18 недель до 2-3 недель при сопоставимом качестве выходных структурных моделей. Baker Hughes представил аналогичный инструментарий – платформу JewelSuite с модулем AI Seismic Interpretation, который на тестовых датасетах Северного моря продемонстрировал точность автоматической трассировки горизонтов на уровне 91-94% против среднего человеческого результата 87-90%.

В России ПАО «Газпром нефть» реализует программу «Цифровое месторождение» с 2018 года. К 2024 году компания сообщила о внедрении AI-систем интерпретации на Новопортовском и Оренбургском месторождениях, где автоматизация позволила сократить трудозатраты геологов на интерпретационные работы на 35-40%. Параллельно «Газпром нефть» совместно с Сколтехом разработала отечественную модель GeoAI, специализированную на геологических разрезах Западной Сибири, – что особенно важно в условиях ограниченного доступа к зарубежному программному обеспечению после 2022 года.

Цифровой двойник пласта (reservoir digital twin) – это динамическая геолого-гидродинамическая модель, синхронизированная с потоком промысловых данных в режиме реального времени. Традиционное полнофизическое моделирование крупного месторождения на сетке из 10-100 млн ячеек требует от нескольких часов до нескольких суток расчётного времени на высокопроизводительных кластерах. Это делает итерационную оптимизацию разработки – перебор сценариев расстановки новых скважин, схем заводнения, изменения дебитов – крайне дорогостоящей задачей.

Наиболее прямой канал экономии от внедрения ИИ – снижение числа «пустых» или низкоэффективных разведочных скважин за счёт повышения точности геологического прогноза. Аналитическая компания Wood Mackenzie в обзоре 2023 года оценила, что улучшение успешности разведочного бурения даже на 5-10 процентных пунктов способно генерировать экономию в 1,5-4,0 млрд долл. в год для глобальной отрасли – с учётом средней стоимости разведочной скважины.

Конкретные примеры подтверждают эту оценку. Shell на блоках в Персидском заливе сообщила о применении ГИИ-систем для выбора мест заложения разведочных скважин: в пилотном проекте 2022-2023 годов успешность бурения в выборке из 12 скважин составила 67% против исторической нормы 38% для сопоставимых блоков [4]. Это означает снижение числа «сухих» скважин с ~7 до ~4 на каждые 12 пробурённых, то есть прямую экономию порядка 90-130 млн долл. на данной выборке при средней стоимости офшорной скважины около 45 млн долл. Компания Equinor также зафиксировала сокращение разведочных расходов на 20–25% на норвежском шельфе после внедрения AI-ассистента Omnia для оценки перспективности структур [5].

В плоскости стоимости добычи аналитики McKinsey оценивают совокупный потенциал снижения удельных CapEx за счёт ИИ-оптимизации в нефтегазовом сегменте в 8-15% к 2030 году – при условии широкого внедрения инструментов прогностического моделирования, оптимизации заканчивания скважин и автоматизации принятия буровых решений [6].

Незапланированные простои наземного и подводного оборудования – насосов, компрессоров, теплообменников, трубопроводных задвижек – являются одним из главных источников OpEx в нефтегазе. По оценке консалтинговой группы ARC Advisory, внеплановые простои обходятся нефтегазовой промышленности в целом примерно в 50 млрд долл. в год [7]. Корень проблемы – в реактивной или плановой стратегиях технического обслуживания, при которых оборудование либо обслуживается по истечении ресурса (без учёта реального износа), либо в момент уже произошедшего отказа.

Системы предиктивного технического обслуживания (PdM) на основе машинного обучения анализируют непрерывные потоки телеметрии – вибрацию, температуру, давление, акустическую эмиссию – и выявляют паттерны деградации за несколько суток или недель до фактического отказа [8]. ВР в рамках программы APEx внедрила PdM-систему на 650 единицах насосного оборудования на месторождениях в Азербайджане и Северном море: по итогам 2021-2023 годов компания зафиксировала сокращение незапланированных простоев на 18%, экономию эксплуатационных расходов – около 47 млн долл. в год по данной группе активов.

Наиболее убедительные кейсы применения ИИ в нефтегазовом секторе сосредоточены в сегменте зрелых месторождений с богатой историей наблюдений. Именно здесь – в противовес распространённому мнению – ИИ демонстрирует наибольшую отдачу: многолетние ряды промысловых данных обеспечивают объём и качество обучающей выборки, необходимые для надёжного прогноза.

Показателен опыт месторождения Ромашкино (Татнефть, Россия) – одного из крупнейших и наиболее изученных в мире. С 2020 по 2024 год компания внедряла ИИ-систему оперативной оптимизации добычи, основанную на ансамблевом обучении (gradient boosting + нейросетевой суррогат пласта). Система в режиме реального времени рекомендует изменения дебитов жидкости и перераспределение нагнетательных объёмов между скважинами. По данным «Татнефти», применение системы обеспечило дополнительный прирост добычи нефти на 1,5-2,3% при неизменном числе действующих скважин, что в пересчёте на годовую добычу месторождения составляет около 250-380 тыс. тонн нефти в год, или порядка 30-45 млн долл. при текущих ценах [9].

Схожие результаты демонстрирует опыт Chevron на месторождениях Пермского бассейна (Техас), где ИИ-оптимизатор гидроразрыва пласта (ГРП) позволил увеличить начальные дебиты новых скважин в среднем на 8-12% при снижении объёма закачиваемого проппанта на 7%, что сокращает одновременно и затраты, и экологическую нагрузку [10]. Срок окупаемости инвестиций в ИИ-инструментарий в данном случае составил, по оценке компании, менее 18 месяцев.

Несмотря на впечатляющие пилотные результаты, широкое промышленное внедрение ИИ в нефтегазовой отрасли сталкивается с несколькими фундаментальными

ограничениями, которые нередко замалчиваются в корпоративных пресс-релизах, но хорошо задокументированы в академической литературе.

Проблема качества данных является, пожалуй, наиболее критичной. Значительная часть действующего фонда скважин – особенно в Восточной Сибири, Средней Азии и ряде африканских стран – оснащена устаревшими датчиками с низкой частотой дискретизации, неполными геофизическими записями и отсутствием стандартизированного цифрового архива. Для таких активов ML-модели, обученные на «богатых» датасетах северноморских или пермских месторождений, переносятся плохо: погрешности прогноза дебитов в подобных условиях достигают 30-50%, что делает практическую ценность модели сомнительной [11].

Проблема старых скважин усугубляется деградацией инфраструктуры. На месторождениях с историей разработки свыше 40-50 лет обводнённость фонда скважин превышает 90-95%, а пластовые условия претерпели столь сложные изменения, что ни суррогатные, ни физические модели не способны адекватно воспроизвести реальную динамику. Попытки применения ГИИ для прогноза остаточных запасов на подобных объектах, по результатам независимого аудита ряда российских активов в 2022-2023 годах, дали погрешности, несовместимые с принятием инвестиционных решений.

Человеческий фактор – третий, и нередко недооцениваемый, барьер. Геологи и инженеры с многолетним опытом склонны воспринимать AI-рекомендации как угрозу профессиональному суждению, а не как инструмент его усиления. Опрос 540 специалистов нефтегазовой отрасли, проведённый Society of Petroleum Engineers в 2023 году, показал: 44% респондентов признали, что в их организациях AI-рекомендации систематически игнорируются или существенно корректируются на операционном уровне без чёткой документации причин. Это не только обесценивает инвестиции в алгоритмы, но и создаёт «невидимые» потери: система работает, отчёты составляются, но фактическое поведение операторов остаётся прежним.

Наконец, регуляторные и суверенные ограничения формируют дополнительный контекст, в котором технические преимущества ИИ реализуются не в полной мере. После 2022 года российские компании лишились доступа к большинству зарубежных облачных ИИ-платформ и части специализированного программного обеспечения, что вынуждает их инвестировать в импортозамещение с нуля – удлиняя горизонт реализации преимуществ как минимум на 3-5 лет. В ряде стран Ближнего Востока и Африки государственные нефтяные компании сталкиваются с требованиями локализации данных, исключающими использование оптимальных облачных архитектур.

Таким образом, реалистичная картина диффузии ИИ в нефтегазовой отрасли существенно сложнее, чем следует из отраслевого маркетинга. Технология создаёт измеримую ценность – но преимущественно там, где есть зрелая цифровая инфраструктура, качественные данные и организационная готовность к изменениям. Там, где этих условий нет – а их нет на значительной части глобального фонда добывающих активов – ИИ остаётся пока дорогостоящим экспериментом без гарантированного возврата инвестиций.

ИИ способен существенно сокращать операционные и капитальные затраты нефтегазовых компаний. Однако у этого технологического выигрыша есть обратная сторона, которая остаётся в тени корпоративных пресс-релизов: сам ИИ является крупным и быстро растущим потребителем электрической энергии. Расчёт полной стоимости владения ИИ-инфраструктурой – включая энергозатраты на обучение моделей, эксплуатацию дата-центров и соответствующий углеродный след – принципиально меняет картину экономической эффективности. Для нефтегазовых компаний эта проблема приобретает особое измерение: они одновременно добывают углеводороды и потребляют энергию для питания вычислительных систем, которые призваны оптимизировать ту самую добычу. Этот парадокс рассматривается в настоящем разделе.

Энергетические затраты на обучение современных нейросетей колоссальны – и долгое время оставались предметом замалчивания как со стороны технологических

компаний, так и со стороны их нефтегазовых заказчиков. Первой системной попыткой измерить углеродный след обучения языковых моделей стала работа Эммы Струбелл и соавторов 2019 года, показавшая, что обучение крупной трансформерной модели генерирует выбросы CO₂, сопоставимые с пятью среднеамериканскими автомобилями за весь жизненный цикл. С тех пор масштаб моделей вырос на несколько порядков.

По оценкам, опубликованным в рецензируемой литературе, обучение GPT-3 (175 млрд параметров) потребовало около 1 287 МВт·ч электроэнергии и сопровождалось выбросами примерно 502 тонны CO₂-эквивалента при использовании типичного американского энергомикса [12]. Для сравнения: среднегодовое потребление электроэнергии одного домохозяйства в США составляет около 10,5 МВт·ч, то есть однократное обучение GPT-3 эквивалентно годовому потреблению примерно 120 американских семей. По более поздним оценкам, обучение GPT-4, параметры которого OpenAI официально не раскрывает, но аналитики оценивают в диапазоне 1-1,8 трлн, потребовало около 50 ГВт·ч – порядка 4 800 домохозяйств-лет.

Важно разграничивать два принципиально разных режима энергопотребления ИИ: обучение (training) и инференс (inference). Обучение – однократный, но чрезвычайно ресурсоёмкий процесс: крупная фундаментальная модель обучается неделями или месяцами на GPU-кластерах. Инференс – эксплуатация обученной модели – менее энергоёмок в расчёте на один запрос, но происходит миллиарды раз в сутки в масштабе продуктивных систем. По оценке Google, суммарные энергозатраты на инференс в её инфраструктуре уже превышают затраты на обучение в соотношении примерно 60:40. Для нефтегазовой отрасли, где промышленные системы работают в непрерывном режиме 24/7 и генерируют запросы к ИИ-моделям каждые несколько секунд, доля инференса в совокупном энергетическом балансе ИИ-инфраструктуры, по всей видимости, ещё выше.

Углеродный интенсивность энергопотребления ИИ-систем существенно зависит от источника электроэнергии. Дата-центр, питаемый от угольной генерации (как значительная часть мощностей в США, Китае, Польше), формирует углеродный след в 0,7-1,0 кг CO₂ на 1 кВт·ч потреблённой энергии; в скандинавских странах с преобладанием гидрогенерации этот показатель падает до 0,02-0,05 кг/кВт·ч [13]. По этой причине часть крупнейших ИИ-компаний (Microsoft, Google, Amazon) целенаправленно размещает вычислительные мощности в регионах с дешёвой и «зелёной» электроэнергией – в Исландии, Норвегии, штате Вашингтон. Нефтегазовые компании, эксплуатирующие ИИ-инфраструктуру на промыслах в Западной Сибири или Техасе, такой возможности, как правило, лишены: вычисления должны производиться вблизи источника данных.

Параллельно с развитием универсальных языковых моделей в нефтегазовой отрасли появляется новый класс систем – геологические фундаментальные модели (Geoscience Foundation Models, GFM). По аналогии с GPT или BERT в НЛП, GFM предобучаются на огромных массивах сейсмических, каротажных и геохимических данных и затем дообучаются (fine-tuned) под конкретные задачи: интерпретацию пластов, прогноз дебитов, идентификацию коллекторов. SLB анонсировала собственную GFM – модель Earth-2 – в 2023 году, подчеркнув, что предобучение потребовало нескольких месяцев работы специализированного GPU-кластера мощностью более 20 МВт.

Для понимания масштаба: GPU-кластер мощностью 100 МВт – это потребление, сопоставимое с небольшим городом. Современный дата-центр гипермасштаба (hyperscale data center), обслуживающий обучение нескольких крупных ИИ-моделей одновременно, потребляет 200-500 МВт электроэнергии. Microsoft в 2024 году объявила о планах строительства ИИ-ориентированных дата-центров суммарной мощностью 3 ГВт к 2026 году – сопоставимо с тремя средними атомными электростанциями. Google в своём отчёте об устойчивом развитии за 2023 год раскрыла, что суммарное потребление её дата-центров превысило 24 ТВт·ч в год – больше, чем потребляет вся Ирландия.

Драйвером столь высокого энергопотребления выступает архитектурная особенность современных ИИ-ускорителей (NVIDIA H100, AMD MI300X): каждый GPU

потребляет 300-700 Вт, а кластер для обучения крупной модели насчитывает тысячи таких чипов. NVIDIA H100 при пиковой нагрузке потребляет около 700 Вт; кластер из 10 000 чипов (типичный масштаб для обучения фронтальной модели) потребляет 7 МВт только на вычисление – без учёта систем охлаждения, которые добавляют ещё 30-50% к суммарному энергобалансу. Если принять коэффициент использования энергии (PUE) современного дата-центра равным 1,2-1,3 (ведущие провайдеры заявляют PUE 1,1-1,15), суммарное потребление объекта составляет 8,5-9,5 МВт – и это лишь один тренировочный прогон одной модели.

Нефтегазовая компания, внедряющая ИИ для оптимизации добычи, попадает в структурно противоречивое положение. С одной стороны, ИИ обещает снизить удельную стоимость извлекаемого барреля и сократить выбросы через повышение операционной эффективности. С другой – вычислительная инфраструктура, обеспечивающая работу этих алгоритмов, требует непрерывного потребления электроэнергии, которая в подавляющем большинстве случаев производится за счёт сжигания углеводородов – тех самых, добыча которых оптимизируется.

Этот парадокс не является чисто умозрительным: он имеет вполне измеримые количественные параметры. По данным Международного энергетического агентства, нефтегазовая промышленность в целом потребляет около 2 200 ТВт·ч электроэнергии в год – приблизительно 6% от мирового производства. Из них значительная часть расходуется непосредственно на объектах добычи и переработки: приводы насосов, компрессоры, системы сепарации, отопление вахтовых посёлков. Добавление к этой нагрузке ИИ-инфраструктуры – пусть и относительно небольшой в абсолютных единицах – создаёт новый класс операционных расходов, который пока не отражается в стандартных метриках углеродного следа компаний.

Принципиально важно, что в отличие от потребления электроэнергии на традиционное нефтепромысловое оборудование (которое нередко уже учтено в Score 1 и Score 2 выбросах по стандарту GHG Protocol), энергозатраты на облачные ИИ-сервисы зачастую попадают в категорию Score 3 – косвенных выбросов по цепочке поставок. Это создаёт иллюзию нейтральности: нефтяная компания закупает вычислительные мощности у Amazon AWS или Microsoft Azure, которые отчитываются о своих выбросах самостоятельно, – и связь между запросом к ИИ-модели и сожжённым газом на электростанции становится статистически невидимой.

Влияние роста ИИ-инфраструктуры на региональные энергосистемы добывающих регионов – один из наименее изученных, но потенциально наиболее острых аспектов проблемы. Добывающие регионы, как правило, обладают ограниченными энергетическими мощностями, ориентированными исторически на нужды добычи и первичной переработки сырья, – но не на энергоёмкие вычисления.

Ханты-Мансийский автономный округ (ХМАО) – крупнейший нефтедобывающий регион России с долей около 42% в общероссийской добыче нефти – обладает суммарной установленной мощностью электроэнергетики около 9,7 ГВт. Около 60% этой мощности сосредоточено на объектах нефтяных компаний (ГПЭС, блочные электростанции), остальное – на объектах «Россетей» и местных генерирующих компаний. Системный оператор ЕЭС фиксирует, что планируемое расширение ИИ-ориентированной инфраструктуры в регионе – в том числе edge-вычислительные узлы крупных нефтяных компаний и региональные дата-центры – создаст дополнительный прирост спроса на 300-600 МВт к 2027-2028 годам. Это сопоставимо с мощностью Сургутской ГРЭС-1 и потребует либо ввода новых генерирующих мощностей, либо существенного роста тарифов для остальных потребителей.

В Техасе, где сосредоточено около 40% добычи нефти США и где Пермский бассейн задаёт темп прироста добычи для всей страны, рост ИИ-инфраструктуры накладывается на уже перегруженную региональную энергосеть ERCOT. Согласно отчёту Техасского совета по надёжности электросистемы, совокупный спрос дата-центров в штате вырастет с 7 ГВт

в 2023 году до 26-32 ГВт к 2030 году – и значительная их часть обслуживает именно нефтегазовый сектор. В условиях, когда ERCOT уже испытывает пиковые дефициты мощности (аномальные холода февраля 2021 года вскрыли уязвимость системы, оставив без электроснабжения 4,5 млн потребителей), добавление крупных вычислительных нагрузок ужесточает конкуренцию за ресурсы сети и создаёт новые системные риски.

Список источников

1. International Energy Agency (IEA). World Energy Investment 2023 [Electronic resource] / IEA. – Paris : IEA, 2023. – 271 p. URL: <https://www.iea.org/reports/world-energy-investment-2023> (дата обращения: 20.05.2026).
2. Kunjan, B. Exploration Chance of Success Predictions – Statistical Concepts and Realities [Electronic resource] / B. Kunjan // ASEG Extended Abstracts. – 2016. – Vol. 1. – P. 1-8. – DOI: 10.1071/ASEG2016ab150. URL: https://www.researchgate.net/publication/314274552_Exploration_Chance_of_Success_Predictions_-_Statistical_Concepts_and_Realities (дата обращения: 21.05.2026)
3. DELFI Environment [Electronic resource] // SLB : [website]. URL: <https://www.slb.com/videos/delfi-environment> (дата обращения: 21.05.2026).
4. Shell Foundation. Report of the Trustees and Financial Statements 2023 [Электронный ресурс] / Shell Foundation. – London : Shell Foundation, 2024. – 28 p. – URL: <https://shellfoundation.org/wp-content/uploads/2024/08/FINAL-Annual-Report-and-Accounts-2023.pdf> (дата обращения: 21.05.2026).
5. Equinor. 2023 Integrated Annual Report [Electronic resource] / Equinor. – Stavanger : Equinor, 2024. – 168 p. URL: <https://cdn.equinor.com/files/h61q9gi9/global/> (дата обращения: 21.05.2026).
6. The next frontier for digital technologies in oil and gas [Электронный ресурс]. URL: <https://www.mckinsey.com/industries/oil-and-gas/our-insights/the-next-frontier-for-digital-technologies-in-oil-and-gas> (дата обращения: 21.05.2026).
7. Cost of Failure in the Oil & Gas Industry – How Much is Too Much? [Электронный ресурс] // ARC Advisory Group. URL: <https://www.arcweb.com/blog/cost-failure-oil-and-gas-industry-how-much-too-much> (дата обращения: 21.05.2026).
8. BP. Sustainability Report 2023 [Электронный ресурс]. – London : BP, 2024. – 96 p. URL: <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/sustainability/group-reports/bp-sustainability-report-2024.pdf> (дата обращения: 22.05.2026).
9. ПАО «Татнефть». Годовой отчёт 2023 [Электронный ресурс]. – Альметьевск, 2024. – 196 с. URL: https://cdn.financemarket.ru/reports/2023/MOEX/T/TATN_2023_12_Y_%D0%9C%D0%A1%D0%A4%D0%9E.pdf (дата обращения: 22.05.2026).
10. Chevron Corporation. Annual Report 2023 [Электронный ресурс]. – San Ramon : Chevron, 2024. URL: <https://www.chevron.com/-/media/shared-media/documents/2023-chevron-annual-report-supplement.pdf> (дата обращения: 23.05.2026).
11. Huang, Y. EfficientNetV2: Smaller Models and Faster Training [Электронный ресурс] / Y. Huang, R. Cheng, Q. Vapna et al. – 2021. URL: <https://arxiv.org/abs/2104.10350> (дата обращения: 23.05.2026).
12. Intergovernmental Panel on Climate Change. Climate Change 2022: Mitigation of Climate Change. Chapter 6: Energy Systems [Электронный ресурс] // IPCC Sixth Assessment Report. – 2022. URL: <https://www.ipcc.ch/report/ar6/wg3/chapter/chapter-6/> (дата обращения: 23.05.2026).
13. Schlumberger [Электронный ресурс]. URL: <https://www.slb.com/> (дата обращения: 24.05.2026).

14. Google. Environmental Report 2023 [Электронный ресурс]. URL: <https://sustainability.google/reports/google-2023-environmental-report/> (дата обращения: 24.05.2026).

Сведения об авторах

Гусейнов Давид Намикович, студент Санкт-Петербургского политехнического университета Петра Великого, Россия, г. Санкт-Петербург.

Сидоров Илья Викторович, студент Санкт-Петербургского политехнического университета Петра Великого, Россия, г. Санкт-Петербург.

Тельпиз Георгий Александрович, студент Санкт-Петербургского политехнического университета Петра Великого, Россия, г. Санкт-Петербург.

Научный руководитель

Бугаева Татьяна Михайловна, к.э.н., доцент, руководитель программы «Экономика инноваций в энергетике».

Information about the authors

Guseynov David Namikovich, Student, Peter the Great St. Petersburg Polytechnic University, Russia, St. Petersburg.

Sidorov Ilya Viktorovich, Student, Peter the Great St. Petersburg Polytechnic University, Russia, St. Petersburg.

Telpiz Georgy Alexandrovich, Student, Peter the Great St. Petersburg Polytechnic University, Russia, St. Petersburg.

Academic Supervisor

Bugaeva Tatiana Mikhailovna, Candidate of Economic Sciences, Associate Professor, Head of the «Economics of Innovations in Energy» Program.