

# СОВРЕМЕННЫЕ ПОДХОДЫ К АВТОМАТИЗАЦИИ ПРОЦЕССА УПЛОТНЯЮЩЕГО БУРЕНИЯ: ОТ ПОИСКА ЗОН ДО ОПТИМИЗАЦИИ ЗАТРАТ ДЛЯ МЕСТОРОЖДЕНИЙ НА ПОСЛЕДНИХ СТАДИЯХ РАЗРАБОТКИ

© Коллектив авторов,  
2024



**А.А. Прохоров<sup>1,\*</sup>, А.Ф. Мурзакова<sup>2</sup>, А.А. Рыбаковская<sup>3</sup>, Д.Н. Сазонов<sup>1</sup>**

<sup>1</sup>Группа компаний «Газпром нефть», РФ, Санкт-Петербург

<sup>2</sup>Санкт-Петербургский политехнический университет Петра Великого, РФ, Санкт-Петербург

<sup>3</sup>Национальный исследовательский Томский политехнический университет, РФ, Томск

**Электронный адрес:** ProNefit@gazprom-neft.ru

**Введение.** Благодаря автоматизации различных процессов разработки происходит повышение экономической эффективности добычи на выработанных месторождениях. Уплотняющее бурение является одним из ключевых мероприятий для увеличения коэффициента охвата и, соответственно, нефтеотдачи на последних стадиях разработки. Современные подходы к поиску новых зон бурения, оптимальному расположению проектного фонда и экономической оценке запусковых параметров все чаще включают использование машинного обучения, аналитику большого объема данных и цифровых двойников.

**Цель.** На основе литературного обзора новейших подходов в области уплотняющего бурения показать наиболее эффективные и пригодные из них для автоматизации процесса подбора кандидатов на крупных активах при условии ограниченного набора данных.

**Материалы и методы.** В работе рассмотрены современные подходы к поиску новых зон для уплотняющего бурения, включая построение карт вероятности и применение машинного обучения для анализа данных, а также техники автоматической интерпретации геофизических данных для выявления пропущенных интервалов коллектора. Описаны методы оптимизации размещения скважин с учетом геологических рисков и экономических факторов. Отмечено, что сложности и риски, связанные с уплотняющим бурением на зрелых месторождениях, подчеркивают необходимость балансировки между точностью и оперативностью методик для эффективного принятия решений.

**Результаты.** Рассмотрены и выделены наиболее эффективные и универсальные методы для каждого этапа планирования уплотняющего бурения, включая построение карт вероятности, оптимизацию размещения фонда и прогнозирование параметров добычи с использованием аналитических методов и машинного обучения.

**Заключение.** Современные подходы к автоматизации уплотняющего бурения, включающие машинное обучение и интеграцию различных моделей, значительно повышают эффективность и точность планирования, однако требуют дальнейших исследований для адаптации к разнообразным условиям эксплуатации.

**Ключевые слова:** уплотняющее бурение, перспективные зоны, ввод новых скважин, машинное обучение, автоматизация бурения, прогноз добычи, оптимизация экономики

**Конфликт интересов:** авторы заявляют об отсутствии конфликта интересов.

**Для цитирования:** Прохоров А.А., Мурзакова А.Ф., Рыбаковская А.А., Сазонов Д.Н. Современные подходы к автоматизации процесса уплотняющего бурения: от поиска зон до оптимизации затрат для месторождений на последних стадиях разработки. ПРОНЕФТЬ. Профессионально о нефти. 2024;9(4):159–172.  
<https://doi.org/10.51890/2587-7399-2024-9-4-159-172>

*Статья поступила в редакцию 19.07.2024*

*Принята к публикации 22.08.2024*

*Опубликована 27.12.2024*

MODERN APPROACHES TO AUTOMATING THE INFILL DRILLING PROCESS ON MATURE FIELDS:  
FROM SELECTION OF INFILL WELLS LOCATIONS TO COST OPTIMIZATION

**Andrey A. Prokhorov<sup>1,\*</sup>, Alina F. Murzakova<sup>2</sup>, Anastasia A. Rybakovskaya<sup>3</sup>, Dmitry N. Sazonov<sup>1</sup>**

<sup>1</sup>Gazprom нефть company group, RF, Saint Petersburg

<sup>2</sup>Peter the Great Saint Petersburg Polytechnic University, RF, Saint Petersburg

<sup>3</sup>National Research Tomsk Polytechnic University, RF, Tomsk

**E-mail:** ProNefit@gazprom-neft.ru

**Introduction.** Thanks to the automation of various development processes, the economic efficiency of extraction in depleted fields is increasing. Infill drilling is one of the key activities for enhancing oil recovery in the later

stages. Modern approaches to locating new drilling zones, optimizing well placement and economically evaluating of initial production increasingly use machine learning, big data analytics and digital twins.

**Aim.** The objective of this article is to conduct a literature review on the latest approaches to infill drilling and highlight the most effective methods for automating the search for well candidates in large fields with limited datasets.

**Materials and methods.** Modern approaches to identifying new zones for infill drilling were explored, including the generation of probability maps and the use of machine learning for data analysis. Additionally, automatic interpretation techniques of geophysical data to identify missed intervals of reservoirs was reviewed. Methods for well placement optimization were described, taking into account geological risks and economic factors. It was noted that the complexities and risks associated with infill drilling in mature fields stress the need to balance accuracy and timeliness of methods for effective decision-making.

**Results.** The most effective and universal approaches for each stage of planning infill drilling were highlighted. The main stages include generating probability maps, well placement optimization and forecasting production parameters using analytical methods and machine learning.

**Conclusions.** Modern approaches to automating infill drilling, which include machine learning and integration of various models, significantly increase the efficiency and accuracy of planning. These methods require further research to adapt to different field development conditions.

**Keywords:** Infill drilling, sweet spots, introduction of new wells, machine learning, drilling automation, production forecast, economic optimization

**Conflict of interest:** the authors declare no conflict of interest.

**For citation:** Prokhorov A.A., Murzakova A.F., Rybakovskaya A.A., Sazonov D.N. Modern approaches to automating the infill drilling process on mature fields: from selection of infill wells locations to cost optimization. PRONEFT. Professionally about oil. 2024;9(4):159–172. <https://doi.org/10.51890/2587-7399-2024-9-4-159-172>

*Manuscript received 19.07.2024*

*Accepted 22.08.2024*

*Published 27.12.2024*

## ВВЕДЕНИЕ

Уплотняющее бурение является эффективным способом повышения нефтеотдачи на поздних стадиях разработки месторождений. Однако, по мере разработки месторождений, бурение новых скважин может становиться менее рентабельным за счет истощения высокопродуктивных залежей/районов объекта, а усилий на поиск выгодных зон затрачивается всё больше. Традиционные методы размещения добывающих скважин основываются на выявлении зон с высоким содержанием подвижных углеводородов в коллекторе на основе анализа экспертной команды большого набора исходных данных, доступ к которым может требовать значительной предварительной проработки (построение моделей, корреляций и пр.). Поэтому стоит рассматривать интегрированные подходы, включающие использование карт вероятности, анализ рисков бурения и качества заканчивания скважин, а также классификацию и ранжирование целей на основе экономической оценки. Из-за того что традиционные методы становятся менее действенными, возникает необходимость в применении инновационных подходов для обработки и анализа большого объема данных с целью принятия оптимальных решений для разработки месторождений. Управление геологическими

неопределенностями имеет решающее значение при планировании бурения для максимизации добычи и экономических показателей. Поиск наилучших зон, определение оптимального количества скважин и их размещение в этих зонах в условиях неопределенности являются предметом многочисленных исследований.

Авторы данной статьи постарались охватить весь спектр современных подходов, которые используются в нефтегазовой отрасли при планировании уплотняющего бурения, а также оценить роль аналитики больших данных и машинного обучения на различных этапах планирования уплотняющего бурения.

## ЦЕЛЬ

С целью повышения эффективности программы уплотняющего бурения с использованием передовых методик рассмотрен обзор современных методов и технологий, направленных на улучшение поиска новых зон, оптимизацию размещения новых скважин и расчет запусковых параметров с учетом экономических факторов. Данный обзор позволил отобрать лучшие практики для применения в рамках текущих проектов и создать качественную базу данных для оперативного и эффективного принятия решений.

## МАТЕРИАЛЫ И МЕТОДЫ

### ПОИСК НОВЫХ ЗОН ДЛЯ БУРЕНИЯ

В данном разделе рассмотрены основные современные методы, применяемые для поиска перспективных и пропущенных зон для уплотняющего бурения, использующие как аналитические подходы, так и подходы машинного обучения.

#### а) Картопостроение

Один из популярных подходов поиска участков нового бурения состоит в построении карт так называемых «sweet spots» или перспективных зон и карт вероятности на основе различных аналитических индексов и оценок, учитывающих свойства коллектора, производительность скважин и всевозможные риски.

Пример такого подхода можно встретить в статье [1], авторы которой для выбора зон уплотняющего бурения на зрелом карбонатном месторождении используют следующие ключевые параметры: свойства коллектора, показатели работы соседних скважин и наличие вызовов в процессе разработки. Далее параметры переводят в три оценки: качества коллектора, потенциала и риска. Итоговый индекс потенциала зоны (Opportunity Score), рассчитанный как взвешенная сумма трех оценок, помогает ранжировать и устанавливать приоритет потенциальных мест для бурения, автоматизируя процесс выбора кандидатов и обеспечивая точность и эффективность принятия решений. Это решение позволяет выявить в 20 раз больше реальных возможностей, чем типичный анализ кросс-функциональной команды, затратив на 75 % меньше времени. Вместо трудоемких

традиционных численных моделей оценка большого количества скважин может быть выполнена в течение нескольких часов, а не месяцев.

В статьях [2, 3] описывается похожий подход поиска и ранжирования перспективных зон, в основе которого лежит Sweet Spot Quality Index (SSQI) или индекс качества перспективной зоны: чем выше SSQI, тем лучше качество перспективной зоны. Данный индекс получается на основе четырех ключевых показателей: индекса качества резервуара (RQI), индекса качества заканчивания (CQI), индекса песчаности (CBI) и операционного индекса (OI). На основе диаграммы важности параметров можно выделить, какие из них имеют наибольшее влияние на SSQI. Данный индекс сочетает в себе характеристику коллектора, стратегии заканчивания скважин, оценку запасов и экономику.

Таким образом, рассмотренные выше методы, основанные на различных эмпирических индексах, помогают оперативно выявить перспективные зоны. Однако они содержат различные весовые коэффициенты, которые определяются на основе комбинации экспертного мнения, анализа данных и обратной проверки, из-за чего в этих методах заложена некоторая субъективность. Наиболее распространенные параметры, используемые при анализе перспективных зон, представлены на **рис. 1**.

Существуют и другие альтернативные подходы поиска зон, в том числе аналитический, на основе карт, и другой, с использованием машинного обучения, которые помогают снизить субъективность и повысить точность прогнозов.



**Рис. 1.** Основные категории исходных данных объекта. Составлено авторами  
**Fig. 1.** The main categories of initial data for a reservoir. Prepared by the authors

Авторы статьи [4] рассматривают оба подхода: первый аналитический — на основе индекса возможностей (Opportunity Index), который вычисляется на основе карт статических и динамических характеристик пласта (песчанистость, нефтенасыщенность, проницаемость, пористость, пластовое давление) и используется для создания карт вероятности, указывающих на перспективные для бурения зоны с высокой вероятностью наличия извлекаемых запасов нефти. Зоны далее

---

**СОВРЕМЕННЫЕ ПОДХОДЫ К ПОИСКУ ЗОН  
ДЛЯ УПЛОТНЯЮЩЕГО БУРЕНИЯ, ВКЛЮЧАЮТ:  
ПОСТРОЕНИЕ КАРТ ВЕРОЯТНОСТИ, АВТОМАТИЧЕСКУЮ  
ИНТЕРПРЕТАЦИЮ ГЕОФИЗИЧЕСКИХ ДАННЫХ  
ДЛЯ ВЫЯВЛЕНИЯ ПРОПУЩЕННЫХ КОЛЛЕКТОРОВ,  
ОПТИМИЗАЦИЮ РАЗМЕЩЕНИЯ ФОНДА И ПРОГНОЗ  
ПАРАМЕТРОВ ДОБЫЧИ С ИСПОЛЬЗОВАНИЕМ  
АНАЛИТИЧЕСКИХ МЕТОДОВ И МАШИННОГО ОБУЧЕНИЯ.**

могут быть использованы для оптимизации размещения скважин с помощью моделирования или методов машинного обучения. Данный подход является довольно распространённым и рассматривается в ряде статей [4, 5, 6, 7]. В статье [7] применяется модифицированный индекс возможностей (Simulation Opportunity Index, SOI), используемый на зрелых месторождениях с карбонатным типом разреза и высокой обводненностью. Методология включает также калибровку водонасыщенности с использованием данных углерод-кислородного каротажа для повышения точности модели и оптимизации размещения скважин. Во втором подходе статьи [4] для автоматической идентификации перспективных зон применяются методы машинного обучения, использующие трехмерную сверточную нейронную сеть, обученную с помощью тройной функции потерь. Модель обучается выявлять и классифицировать зоны, как целевые и нецелевые, на основе индекса возможностей (Opportunity Index) и других геологических характеристиках. Преимущество подхода, основанного на машинном обучении, заключается в автоматизированной оценке и оптимизации производительности выявленных объемов перспективных зон, а также в более качественном выборе участков, что снижает трудоемкость и временные затраты. Таким образом, в эпоху развития технологий методы машинного обучения являются популярным и перспективным направлением для исследований в нефтегазовой отрасли. Подходы machine learning (ML) и анализа данных предлагают перспективные решения

задач при разработке месторождений, в том числе и при поиске перспективных зон бурения, оптимизации размещения скважин и их добычи, разработки стратегии или интерпретации больших объемов промысловых данных.

Например, в статьях [8, 9] для поиска зон уплотняющего бурения и прогнозирования производительности новых скважин описывается подход на основе интегрированного анализа данных. В обоих источниках первым этапом выполняется кластеризация скважин на основе ключевых показателей эффективности (KPI) скважин, например, на основе стартового дебита (низкий, высокий) и среднего дебита нефти за первые 3 года (низкий, средний, высокий) [8], или с использованием алгоритма многомерной кластеризации (SOM) [9]. На этом же этапе для каждого кластера определяется характерная кривая темпов падения, описывающая наиболее вероятные профили производительности с учетом неопределенностей.

Оба подхода используют байесовскую сеть. В статье [8] она строится для выявления особенностей, определяющих принадлежность скважины к тому или иному кластеру, и включает в себя узлы с дискретными состояниями, такими как начальная нефтенасыщенность, длина заканчивания и эмпирическая функция пористости. В то же время в статье [9] сеть используется для определения вероятностных зависимостей между параметрами скважин (координаты, время бурения, расстояние между скважинами и т.д.) и типовыми кривыми.

В статье [8] полученная байесовская сеть и двумерные карты позволяют выявить и ранжировать потенциальных участков для бурения, создавая карту перспективных зон с характерными параметрами для каждого кластера. Во втором подходе авторы статьи [9] с помощью сети получают вероятность того, что новая скважина будет соответствовать определенной типовой кривой, и уделяют больше внимания технологическим и экономическим данным.

Таким образом, оба метода значительно повышают эффективность и точность поиска зон и прогнозов добычи скважин за счет использования байесовских сетей. В первом случае интеграция с геологическими данными улучшает точность пространственных прогнозов, тогда как во втором подходе акцент на производительности и учет экономических показателей помогает лучше оценивать экономическую целесообразность бурения. В статьях российской компании Sfofil [10, 11, 12, 13, 14] описывается интегрированная методика для планирования разработки

месторождения, включающая как методы аналитики истории добычи, так и ML подходы к поиску зон для бурения новых скважин. Ключевыми этапами являются первичный анализ данных (Prime анализ), калибровка 3D-модели месторождения и многовариантное планирование разработки (MSDP). В ходе работ проводится детальное исследование межскважинного взаимодействия с помощью методов мультискважинного ретроспективного тестирования (MPT) и импульсно-корового гидропрослушивания (ИКГ), что способствует повышению эффективности вытеснения нефти и увеличению коэффициента извлечения.

Многовариантное планирование разработки (MSDP) основано на использовании цифровых двойников месторождений и специальных программных средств, таких как PolyPlan, для моделирования различных сценариев разработки и их экономической оценки. Такая интегрированная методика обладает несомненными плюсами: повышенная точность, оптимизация операций, интеграция передовых процессов, однако она также имеет и минусы. Внедрение и поддержка таких технологий требуют значительных финансовых вложений, что может быть недоступно для некоторых компаний. Также интеграция различных методик и технологий нуждаются в высоком уровне квалификации персонала и сложной координации между различными специалистами. Процесс сбора данных, их анализа и калибровки моделей может занять значительное время, что замедляет принятие решений и реализацию проектов.

Поэтому в условиях ограниченных временных, денежных и информационных ресурсов необходимо выдерживать баланс между точностью и оперативностью методик. Подбирать наиболее окупаемые и эффективные подходы.

#### ***б) Поиск пропущенных интервалов***

В данном разделе рассматриваются методики поиска пропущенных интервалов нефтенасыщенного коллектора с использованием автоматической интерпретации геофизических исследований скважин (ГИС). Такой подход может быть использован как для внутрискважинных работ в уже пробуренных скважинах (дострелы, резрезка боковых стволов), так и для уплотняющего бурения и поиска новых залежей.

Традиционный рабочий процесс интерпретации ГИС является трудоемким и субъективным, а результат зависит от экспертизы и опыта геолога-петрофизика. Интерес к использованию машинного обучения для решения этой проблемы возник еще много

лет назад. Алгоритмы машинного обучения могут оперативно анализировать исторические данные разработки и идентифицировать зоны, которые оказались пропущены при первоначальном бурении.

Нарастающее количество исследований [15, 16, 17, 18] показало, что глубокая сверточная нейронная сеть (CNN) может обеспечить точный и эффективный подход для интерпретации данных каротажа скважин. В работе [15] для прогноза пространственного расположения перспективных зон сланцевого газа авторы предлагают использовать в качестве параметров ГИС: скорость и плотность продольных и поперечных волн, модуль упругости и коэффициент Пуассона. Используя геофизические сейсмические данные и обученную модель 1D-CNN, такой метод позволяет с высокой точностью предсказывать такие ключевые параметры, как общее органическое содержание углерода (TOC), пористость (PHI) и содержание газа (GAS) и получить трёхмерное распределение перспективных зон, что существенно облегчает поиск и разработку новых экономически рентабельных зон.

Для автоматической интерпретации данных геофизических исследований с целью поиска пропущенных продуктивных интервалов, ранее не интерпретированных как нефтеносные, авторы статей [16, 17, 18] разработали модели машинного обучения, также использующие рекуррентные и сверточные нейронные сети. В качестве исходных данных использовался расширенный комплекс ГИС, включая гамма-каротаж (GR), потенциалы спонтанной поляризации (SP), индукционные каротаж (ILD, LLD) и нейтронный каротаж (NKTД). Изначально массив данных был построен на основе одного месторождения, затем расширен до набора данных, включающего шесть крупных месторождений Западной Сибири. Стоит отметить, что имеются ограничения по использованию данных ГИС скважин, связанные с типом и наличием минимального комплекса каротажных кривых. Задача поиска пропущенных интервалов решалась как задача обучения с учителем с использованием каротажных кривых и соответствующих им интерпретаций прошлых лет. В качестве целевой переменной авторы использовали бинарную классификацию (например, «нефть»/«не нефть») или многоклассовую классификацию (например, «нефть», «вода», «плотная порода», «не коллектор»). Кроме того, рассмотрена модель ранжирования, которая имитирует процесс принятия решений эксперта и оценивает потенциал нефтенасыщенности предложенных интервалов, сортируя их по уровню уверенности.

Методология была протестирована на двух месторождениях Западной Сибири и, по данным авторов, помогла открыть новые продуктивные интервалы, что позволило увеличить добычу нефти из ранее недооцененных скважин.

В другой статье [19] для этой цели авторы рассматривают три группы алгоритмов машинного обучения: случайный лес, градиентный бустинг и нейронные сети (многослойный перцептрон, MLP). Все три алгоритма показали уверенную способность предсказывать литологию по стандартному набору коротких кривых без нормировки на опорные пласты. Также, выделено, что алгоритмы машинного обучения могут сократить время на предварительную подготовку кривых, сохраняя при этом высокое качество предсказаний.

### ОПТИМИЗАЦИЯ РАСПОЛОЖЕНИЯ ПРОЕКТНОГО ФОНДА С УЧЕТОМ РИСКОВ

Оптимизация размещения проектного фонда в новых зонах требует учета множества факторов, включая геологические условия, риски и работу окружающих скважин. Современные методы, основанные на использовании разного вида моделей, множества симуляторов, оптимизаторов, методик машинного обучения, позволяют быстро прогнозировать результаты бурения в различных точках и минимизировать риски.

Подход, применяемый с использованием системы, состоящей из нескольких интегрированных моделей резервуаров и поверхностных объектов, является наиболее распространенным и позволяет учитывать различные комбинации пластового описания и инфраструктуры.

Система генерирует множество вариантов разработки месторождений, которые проходят через оптимизатор с учетом рисков и неопределенностей. Оптимизация нацелена на максимизацию экономических показателей или/и на показатели добычи с учетом ограничений на разработку месторождений. В качестве оптимизационных алгоритмов для решения многопараметрических задач, которой и является расстановка проектного фонда, могут использоваться: вариации генетического алгоритма (GA), метод имитации отжига, метод роя частиц (PSO) и др.

Например, в статье [20] представлена технология, которая основана на усовершенствованном генетическом алгоритме (Enhanced Genetic Algorithm, EGA), применяемом для оптимизации множества параметров, таких как расположение новых и боковых стволов скважин, график бурения, стратегии закачки воды и газа, а также давления в наземной

инфраструктуре на крупных новых и зрелых месторождениях. Технология позволяет учитывать неопределенности в описании пласта и интегрировать модели как подземных, так и наземных объектов для комплексного решения задачи.

Также для оптимизации расположения скважин часто используется алгоритм роя частиц (PSO) [21, 22]. Существуют примеры применения как на синтетических моделях [22], так и на реальных месторождениях [21]. Основными критериями оптимизации в представленных статьях являются максимизация суммарной добычи нефти из определенного сектора месторождения [21] и чистая приведенная стоимость (NPV) актива [22]. Данные примеры подчеркивают эффективность алгоритма роя частиц для решения сложных задач оптимизации размещения скважин, предоставляя полезные инструменты для инженеров-нефтяников.

Статья [23] описывает методологию оптимизации размещения скважин с использованием дополненного искусственного интеллекта в сочетании с человеческой экспертизой для улучшения принятия решений. В первую очередь были собраны и обработаны данные о скважинах, включая более 60 признаков, таких как геологические параметры, параметры траектории скважин, данные о гидроразрыве пласта. Для построения и ассемблирования моделей были применены алгоритмы случайного леса и регрессии Лассо. При интерпретации результатов использовался метод SHAP (Shapley Additive Explanations) для объяснения вклада различных признаков в предсказания моделей, что позволило понять, какие факторы наиболее значительно влияют на начальную производительность и конечное извлечение. Гибридный метод позволил создать точную и объяснимую модель для оптимизации размещения скважин.

Достаточно широко для решения данной задачи применяются градиентные методы оптимизации, как классический алгоритм [25], так и метод стохастического приближения [24]. Используемые в источниках методики включают интеграцию алгоритмов с симулятором резервуаров Eclipse для повышения точности поиска оптимальных местоположений и интервалов перфорации скважин. В целом, подходы «умного» перебора обладают высокой точностью, но очень трудозатратны, требуют тщательной подготовки данных и верификации всех моделей. Часто на подбор оптимального сценария уходит от нескольких дней до нескольких недель. Поэтому постоянно идет поиск путей улучшения и ускорения текущих подходов

оптимизации. Каждый цикл симуляции на моделях — затратный по времени процесс, поэтому сокращение их числа приоритетная задача. В статье [26] представлен метод DQN (Deep Q-Network) для оптимизации производительности резервуаров, который распределяет задачи между несколькими вычислительными узлами для параллельного нахождения оптимумов. По результатам сравнительных тестов параллельный расчет значительно снижает вычислительные затраты по сравнению с ранее рассмотренными методами, обеспечивая при этом высокое качество оптимизации.

Для ускорения расчетов с оптимизационными алгоритмами, могут использоваться прокси-модели процесса [27], которые позволяют значительно уменьшить число необходимых симуляций, сохраняя при этом точность и надежность оптимизационных решений, однако также требуют предобучения.

В свою очередь могут быть эффективны и более примитивные методы оптимизации, работающие на рекурсивном подборе, которые подкреплены пользовательскими правилами. Например, статья [28] описывает методику автоматизированной оптимизации расположения скважин WISH (Well Improvement Scheme). WISH применяет генеративный дизайн, автоматизирующий процесс создания схем скважин, балансируя различные правила позиционирования и используя динамическое моделирование резервуаров.

В источнике [6] рассматривается другой подход, использующий в качестве базы создание и интеграцию карт вероятности, рисков бурения и качества заканчивания скважин. На их основе модель машинного обучения классифицирует резервуар на целевые и нецелевые зоны и далее использует метод «черной дыры» (Black Hole Method) для размещения добывающих и нагнетательных скважин.

Данный алгоритм вдохновлен поведением черных дыр в астрономии, где лучшее решение «поглощает» близкие худшие в популяции. Таким образом, происходит автоматическая оптимизация расстановки новых скважин с учётом экономических факторов. Кроме представленных методов оптимизации, для решения задачи расположения и бурения проектного фонда также может быть использовано глубокое обучение. Например, статьи [29, 30] описывают разработку автоматического планировщика скважин (AWP) для сложных траекторий, который использует нейронные сети для адаптации траекторий скважин к локальным геологическим и гидродинамическим условиям резервуара. Такой подход можно применить и к поиску оптимального расположения

новых скважин в зонах скопления запасов, дополнив обучающий набор данных.

Один из таких подходов описан в статье [31], где применяется методика оптимизации размещения скважин, в которой используется метод латинского гиперкуба (Latin Hypercube Sampling, LHS) и нейронная сеть с радиальными базисными функциями (Radial Basis Function Network, RBFN). LHS генерирует точки на карте в формате (X, Y), представляющие возможные местоположения скважин, обеспечивая равномерное распределение параметров по исследуемому пространству. Эти точки затем используются для тренировки прокси-модели искусственного интеллекта (RBFN), которая предсказывает оптимальные места для бурения с целью увеличения добычи нефти и снижения добычи воды. Методика помогает существенно сократить время вычислений и повысить точность предсказаний, улучшая экономические показатели.

Еще один пример успешного применения глубинного обучения на основе сверточных нейронных сетей (DCNN) представлен в статье [32]. DCNN модели обладают способностью обрабатывать сложные многомерные данные, что делает их особенно эффективными для задач, связанных с оптимизацией размещения скважин в сложных геологических условиях. Применение нейронных сетей позволило значительно повысить точность прогнозов и сократить время анализа на 85%, по сравнению с традиционным подходом [33]. Таким образом, на сегодняшний день существует большое количество подходов к автоматизации и оптимизации размещения скважин, которые показывают свою эффективность и точность, но требуют большого количества данных и вычислительных ресурсов. Также стоит отметить, что к выбору того или иного метода на каждом месторождении/объекте следует подходить индивидуально.

## ЭКОНОМИЧЕСКАЯ ОЦЕНКА И ПРОГНОЗ ЗАПУСКНЫХ ПАРАМЕТРОВ

Экономическая оценка учитывает затраты на бурение и потенциальную прибыль, что позволяет принимать обоснованные решения. Применение аналитических методов и полноценных интегрированных моделей дает возможность более точно прогнозировать результаты и оптимизировать затраты. Учет экономических параметров присутствует практически в каждом подходе из предыдущей главы, так как логично, что оптимальное расположение фонда должно быть обусловлено в первую очередь наибольшей прибылью для коммерческих компаний [20, 22, 24, 25, 26, 34]. Однако в некоторых

источниках приоритет отдается максимизации объема добычи нефти [21, 27, 28, 29, 30, 31]. Многопараметрическая оценка сценариев по двум критериям: суммарной добычи нефти и NPV, показала, что оптимизация добычи может не всегда приводить к максимальному NPV [34]. В свою очередь, оптимизация этого показателя максимизирует краткосрочные экономические выгоды, но может не обеспечивать максимальную добычу нефти в долгосрочной перспективе. Использование многокритериального подхода позволяет сбалансировать эти два показателя в зависимости от приоритетов компании, обеспечивая как экономическую эффективность, так и устойчивость добычи [34]. Это позволяет быстро изменять приоритет оптимизации и реагировать на запросы рынка. Похожий подход, основанный на не прямой максимизации NPV и/или накопленной добычи, применялся авторами статьи [35] для поиска зон бурения с учетом геологических и экономических неопределенностей. Методика оценки экономической эффективности бурения новых скважин заключается в использовании вероятностных карт свойств для выявления потенциальных мест бурения и прогнозирования дополнительной добычи нефти. Для оптимизации выбора скважин используется теория полезности, что позволяет учитывать отношение компании к риску. Функция полезности (PES) преобразует NPV каждой скважины в меру полезности, которая учитывает риск и определяется как вероятность получения  $NPV \geq 0$  на основе множества моделей. Авторы предлагают использовать зависимость PES от NPV для визуализации экономических параметров и сравнения неопределенности различных вариантов. Форма функции определяет, является ли принимающее решение нейтральным к риску, склонным к риску и отсутствию рисков. В результате вместо NPV параметром оптимизации выступает ожидаемая полезность в соответствии с предпочитаемым уровнем риска. Таким образом, выбор стратегии оптимизации должен зависеть от конкретных целей и приоритетов нефтяной компании, будь то максимизация прибыли, поддержание устойчивой добычи нефти на длительный срок или желаемый уровень риска сценария. Впрочем, любая экономическая оценка основана на динамических параметрах скважины. От качества расчета запусковых параметров и прогноза добычи новой скважины зависит, какой PI будет иметь сценарий. Существует несколько распространенных подходов к расчету продуктивности скважин, в т.ч. аналитические методы, основанные,

например, на уравнении фильтрации Дюпюи или Джоши и вероятностные подходы, промысловые гидродинамические исследования и гидродинамическое моделирование, а также методы, основанные на анализе данных и ML.

Один из аналитических методов рассмотрен авторами статьи [3], в которой помимо индекса качества перспективной зоны (SSQI), описанного в разделе «Картопостроение», рассматривается Индекс производительности скважин (SPI). Данный индекс используется для прогнозирования дебита скважин на основе моделей ML и получается на основе значений RQI (Индекса качества резервуара) и CQI (Индекса качества заканчивания). Авторы утверждают, что индекс производительности скважин (SPI) демонстрирует сильную корреляцию с фактической производительностью скважин и служит надежным инструментом для прогнозирования добычи. В статье [36] описывается применение эмпирического и вероятностного подходов для прогноза добычи новых скважин на одном из месторождений Австралии. Авторы основывались на анализе результатов предыдущих буровых кампаний и рассмотрели два основных алгоритма для прогноза добычи скважин: один подход предсказывает начальный дебит на основе среднего дебита жидкости соседних скважин и обводненности, а другой — использует различные соотношения накопленной добычи нефти к текущей/накопленной обводненности. С помощью метода Монте-Карло сгенерировано множество возможных исходов для ключевых параметров, таких как NPV, что позволило точно оценить вероятность достижения различных экономических показателей и принять обоснованные решения. Однако рассмотренные в статье алгоритмы содержат эмпирические коэффициенты, которые вносят некоторую субъективность в прогноз параметров.

Среди методов искусственного интеллекта (ИИ) для прогноза добычи распространённым методом является использование искусственных нейронных сетей (ИНС). Такой подход представлен в статье [37], где обсуждается методология использования ИНС для поиска сложных взаимосвязей между геологическими, сейсмическими и короткими данными скважин, параметрами заканчивания и характеристиками добычи. Данный метод используется для прогнозирования накопленной добычи нефти, воды и газа за двухлетний период на неразбуренных участках и был протестирован на нефтяном низкопроницаемом пласте. Для разработанной сети точность средней ошибки

составила ~13% в случаях тестирования и ~5% в случаях обучения.

Еще одним популярным современным методом ИИ для прогнозирования продуктивности скважин является метод опорных векторов, который рассмотрен в статье [38]. Авторы предлагают двойную модель, в которой первая часть обучается на фильтрационных параметрах и предсказывает начальный дебит, а вторая часть — на емкостных и предсказывает годовую добычу нефти, с учетом всех геолого-промысловых данных. Метод опорных векторов используется для классификации и последующего ранжирования скважин и позволяет учитывать сложные многомерные зависимости между параметрами, делая прогнозирование более точным в условиях сложного строения пластов.

Другой современный подход прогноза продуктивности нефтяных скважин, основанный глубокими нейронными сетями (DNN) и градиентном бустинге (XGBoost) рассматривается в статье [39]. Оптимизация гиперпараметров моделей (градиентный спуск SGD, Adam и RMSprop) и использование XGBoost позволили выявить ключевые факторы, влияющие на продуктивность скважин, такие как вязкость нефти, пористость и проницаемость. По сравнению с традиционными методами, такими как моделирование и интерпретация ГИС, модель глубоких нейронных сетей демонстрирует высокую точность прогнозирования продуктивности скважин обрабатывать сложные нелинейные зависимости в данных, что обеспечивает высокую точность прогнозов.

## ПРОБЛЕМАТИКА ТЕКУЩИХ РЕШЕНИЙ

Оперативное управление разработкой месторождений на последних стадиях требует рационального подхода, который в первую очередь диктуется ограниченностью финансовых и временных ресурсов, а также имеющимся набором исходных данных. Сочетание полноты исходных данных и временных рамок реализации проекта определяют инструментарий и качество решения задачи (рис. 2).

Работы по уплотняющему бурению содержат в себе много неопределенностей, но главная из них состоит, в первую очередь, в нерентабельности бурения новых скважин. Поэтому тратится много экспертного времени на первичный скрининг объектов и зон с целью выявления перспективных площадей.

Обосновать будущие затраты на разработку участка, заинтересовать бизнес в разработке и снижении рисков — это основная задача команды экспертов. Поиск таких зон часто проводится в слепую, на самых «популярных»

объектах со знакомой для эксперта историей разработки. На достаточно крупных активах интересные участки могут теряться в общем объеме кандидатов из-за человеческого фактора.

Основные принципы и экспертные правила при выборе участков для бурения имеют общую логику, поэтому могут быть автоматизированы. Первичный скрининг зон с необходимым уровнем уверенности для формирования бизнес-кейсов, можно проводить на основе накопленных за историю разработки данных, без проведения дополнительных мероприятий. При таком подходе эксперты могут быть уверены в полном охвате ресурсной базы актива и сконцентрироваться на выявленных уверенных кандидатах.

Как видно из обзора методик, на данный момент практически все автоматизированные решения связаны с тяжеловесными моделями пласта и инфраструктуры в совокупности с грузными оптимизационными алгоритмами, которые требуют тщательной подготовки большого объема данных и чаще всего доисследования участков и дополнительных вложений. Так как создание геологических и гидродинамических моделей является сложным и трудозатратным процессом и для многих объектов — это недоступная роскошь, необходимо сосредоточиться на имеющихся картах, аналитических подходах и легких оптимизационных алгоритмах, учитывающих риски и неопределенность. Также гибкая и понятная структура алгоритма облегчит восприятие результатов




Рис. 2. Классификация подходов (методик) поиска районов под уплотняющее бурение. Составлено авторами

Fig. 2. Classification of infill drilling approaches. Prepared by the authors

экспертами и исключит работу с «черным ящиком».

Усложнение и интеграция моделей всех физических процессов, которые составляют разработку недр, не всегда оправдывает итоговый прирост. Включение в модель сколь угодно большого набора данных приводит к утяжелению процесса расчета. Также распространённым является создание модели в периметре ограниченного по физическим свойствам объекта, что позволяет решать только локальную задачу. Это связано с тем, что чем более точно мы стремимся предсказать результат, тем более конкретно мы подходим к описанию условий добычи. В такой модели любая переадаптация на другие условия требует дообучения или переобучения. Такой алгоритм машинного обучения тяжело назвать универсальным. Получение качественной всеохватывающей модели требует разнопрофильных данных с разных объектов разработки, их обработку и интеграцию, учет всех параметров, которые отражаются на желаемой метрике. Пренебрегая наименее значимыми параметрами, можно сосредоточиться на основных критериях лучшего решения и принять во внимание все их многообразие реализации.

В таком случае помощь автоаналитика должна заключаться, в первую очередь, в экспресс-скрининге, валидации исходных данных и быстрых подсказках, на которые должен обратить внимание эксперт, а не в поиске «идеального» варианта. Подготовка и выбор

оптимального решения с необходимым соотношением уровней добычи и экономической эффективности все еще остается задачей эксперта.

## РЕЗУЛЬТАТЫ

Опираясь на проведенный литературный обзор и текущую проблематику области, также учитывая недостатки каждого метода, можно выделить эффективные, универсальные и наименее трудозатратные методы для каждого этапа планирования уплотняющего бурения (рис. 3).

Так, для реализации поиска зон наиболее оптимальным аналитическим подходом, является метод построения карт вероятности перспективных зон на основе индекса возможностей. Данный индекс можно модифицировать в зависимости от имеющихся исходных параметров. Наиболее важными представляют собой: песчанистость, нефтенасыщенность, проницаемость, пористость, пластовое давление. В качестве дополнительных опций можно учесть: показатели работы соседних скважин, наличие проблем в процессе разработки, техническую оценку буримости зоны.

Наиболее зарекомендованным и распространенным методом поиска пропущенных интервалов является глубокая сверточная нейронная сеть (CNN), которая при достаточно обширном массиве данных позволяет




Рис. 3. Блок-схема процесса уплотняющего бурения и обзор рассмотренных современных методик автоматизации для каждого из этапов согласно классификации подходов на рис. 2. Составлено авторами

Fig. 3. Workflow of the infill drilling process and overview of the considered modern automation techniques of each stage assessment according to the classification of approaches in Fig 2. Prepared by the authors

обеспечить точную интерпретацию геофизического каротажа скважин.

Гибко оптимизировать расположение фонда в выделенных перспективных зонах позволяет весовая функция соотношения NPV и накопленной добычи.

Параметры добычи новой зоны достаточно вариативно оцениваются на основе моделей машинного обучения. Точность данного подхода во многом зависит от объема «качественно» отобранных реальных данных. Поэтому имеет смысл основу расчета производить аналитически, так как не все участки имеют достаточный объем исторически корректных данных. Впоследствии можно использовать ML модели для кластеризации скважин и выделения зон. Данные методы позволяют находить оптимальные решения, сохраняя баланс между затраченным временем и точностью, в условиях ограниченного набора данных.

## ЗАКЛЮЧЕНИЕ

С появлением мощных компьютеров и передовых алгоритмов машинного обучения,

методы ML внедряются как интегрированные инструменты, а также как альтернатива традиционным подходам. На основе проведенного обзора установлено, что методы ML обладают огромным потенциалом в решении задач в нефтегазовой отрасли и с увеличением количества данных становятся необходимостью для более эффективного управления разработкой месторождений. Помимо методов машинного обучения и анализа данных в статье рассмотрен ряд популярных аналитических и эмпирических подходов, которые обладают меньшей точностью, но могут быть применены для улучшения процесса принятия решений в условиях ограниченного набора данных.

Дополнительные исследования в области адаптации методов к различным типам месторождений и условий эксплуатации будут способствовать дальнейшему развитию технологий и повышению эффективности процесса уплотняющего бурения. Особое внимание следует уделить разработке гибких и адаптивных методик, которые помогут быстро подстраиваться к изменяющимся условиям рынка и ограничениям.

## Список литературы

1. Mata C., Saputelli L., Badmaev D., Zhao W., Mohan R., Gönczi D. Automated Reservoir Management Workflows to Identify Candidates and Rank Opportunities for Production Enhancement and Cost Optimization in a Giant Field in Offshore Abu Dhabi. Offshore Technology Conference, Houston, TX, USA. 2021. OTC 31295
2. Algarhy A., Bateman R.M., Soliman M.Y. An Innovative Technique To Evaluate Shale Sweetspots: A Case Study From North Africa. SPWLA 56th Annual Logging Symposium held in Long Beach, California, USA. July 18–22, 2015
3. Algarhy A., Ibrahim A.F., A. Gabry M., Ali Amr G. Predicting Shale Production Performance Through Machine Learning: The Development and Application of the Sweet Spot Quality Index. Society of Petroleum Engineers, Wheeling, West Virginia, USA. 2023. SPE 215911
4. Su Sh., Schulze-Riepert R., Mustapha H., Lang Ph., Kloucha Ch.K. Artificial Intelligence for Infill Well Placement and Design Optimization in Multi-layered/stacked Reservoirs Under Subsurface Uncertainty. Society of Petroleum Engineers, Abu Dhabi, UAE. 2021. SPE 207899
5. Pongtepupathum W., Lang Ph., Adeyemi T. An Ensemble-Based Infill Well Location Solution: A Cloud Native Application for Automating Well Placement and Evaluation. Society of Petroleum Engineers, Abu Dhabi, UAE. 2022. SPE 211361
6. Su Sh., Tahir S., Ghorayeb K., Ramatullayev S., Garcia-Teijeiro X. Multidisciplinary Data Integration for Artificial-Intelligence-Assisted Well Placement and Trajectory Design Optimization Under Uncertainty. Society of Petroleum Engineers, Abu Dhabi, UAE. 2022. SPE 211367
7. Bernadi B., Silalahi Eli S., Reksahutama A., Miraza D. Infill Wells Placement in High Water-Cut Mature Carbonate Field with Simulation Opportunity Index Method. Society of Petroleum Engineers, Bali, Indonesia. 2019. SPE 196388
8. Zijlstra E., Rietmuller G., Schäfflein S., Mahruqi S. Using Marketing Technology in Reservoir Engineering: The Application of Data Driven Predictive Analysis on a Mature Oil Field. International Petroleum Technology Conference, Bangkok, Thailand. 2011. IPTC 14676
9. Al-Kinani A., Nunez G., Stundner M., Zangl G., Mata T., Cottone S. Selection of Infill Drilling Locations Using Customized Type Curves. Society of Petroleum Engineers, Cartagena, Columbia. 2019. SPE 122186
10. Aslanyan A., Kovalenko I., Ilyasov I., Gulyaev D., Buyanov A., Musaleev Kh. Waterflood study of high viscosity saturated reservoir with multiwell retrospective testing and cross-well pressure pulse-code testing. Society of Petroleum Engineers, Kuwait City, Kuwait. 2018. SPE-193712-MS
11. Aslanyan A., Asmadiyarov R., Kaeshkov I., Bikkulov M., Farakhova R., Krichevsky V., Gulyaev D., Musaleev Kh. Multiwell deconvolution as important guideline to production optimisation: Western Siberia Case Study. The International Petroleum Technology Conference, Beijing, China. 2019. IPTC-19566-MS
12. Aslanyan A., Grishko F., Krichevsky V., Gulyaev D., Panarina E., Buyanov A. Assessing waterflood efficiency with deconvolution based multi-well retrospective test technique. Society of Petroleum Engineers, London, England, UK. 2019. SPE195518-MS
13. Новаленко И.В., Немирович Г.М., Ильясов И.Р., Буянов А.В., Гуляев Д.Н. Применение технологии импульсно-кодowego гидропрослушивания при заводнении в сложных геологических условиях // Нефтяное хозяйство. — Июнь, 2018.
14. Sabzabadi A., Masoudi R., Arsanti D., Aslanyan I., Garnyshev M., Minakhmetova R., Karancharat R. Verifying Local Oil Reserves Using Multi-Well Pressure Pulse Code Testing. Off-shore Technology Conference Asia, Kuala Lumpur, Malaysia. 2018. OTC-28601-MS
15. Qin Zh., Xu T. Shale gas geological "sweet spot" parameter prediction method and its application based on convolutional neural network. Scientific Reports, Nature Portfolio, China. 2022. <https://doi.org/10.1038/s41598-022-19711-6>
16. Egorov D.V., Sabirov A.R. Applying Machine Learning Methods to Search for Missing Net Pay Zones in Mature Oilfields Wells. Society of Petroleum Engineers, Moscow, Russia. 2019. SPE 196869

17. Semenikhin A.S., Shchepetnov A.A. Missed Net Pay Zones in Mature Oilfields Via Injection of Expert Knowledge in Deep Learning Algorithms. Society of Petroleum Engineers, Moscow, Russia. 2020. SPE 201922
18. Белозеров Б.В., Буханов Н.В. Автоматический анализ геофизических исследований скважин на Приобском месторождении с использованием методов машинного обучения // Авторское право 2018, Общество инженеров нефтегазовой промышленности. — Москва, 2018. SPE 191604-18RPTC-RU
19. Сахнюк В.И., Новиков Е.В., Шарифуллин А.М., Белохин В.С., Антонов А.П. Применение методов машинного обучения в обработке данных геофизических исследований скважин отложений викуловской свиты // Московский государственный университет имени М.В. Ломоносова. — Москва. — 2022. — Т. 24. — № 2. — С. 230–238. <https://doi.org/10.18599/grs.2022.2.21>
20. Litvak M., Gane B., Williams G. Field Development Optimization Technology. Society of Petroleum Engineers, Houston. 2007. SPE 106426
21. Roussennac B., Gijss van Essen. Streamlining the Well Location Optimization Process — An Automated Approach Applied to a Large Onshore Carbonate Field. Society of Petroleum Engineers, Dubai, UAE. 2021. SPE 205913
22. Boah E.A., Senyo Kondo O.K., Borsah A.A. Critical Evaluation of Infill Well Placement and Optimization of Well Spacing Using the Particle Swarm Algorithm. Journal of Petroleum Exploration and Production Technology. 2019, no. 9 (4). <https://doi.org/10.1007/s13202-019-0710-1>
23. Ma Zh., Davani E., Ma X. Finding a Trend Out of Chaos: A Machine-Learning Approach for Well-Spacing Optimization. Society of Petroleum Engineers, Denver, Colorado, USA. 2020. SPE 201698
24. Li C., Fang Ch., Huang Y., Zuo H. Infill well placement optimization for secondary development of waterflooding oilfields with SPSA algorithm. Frontiers in Energy Research. 2022. <https://doi.org/10.3389/fenrg.2022.1005749>
25. Forouzanfar F., Li G., Reynolds A.C. A two-stage well placement optimization method based on adjoint gradient. Society of Petroleum Engineers, Florence, Italy. 2010. SPE 135304
26. Alpak F., Wang Y., Gao G. Benchmarking and Field-Testing of the Distributed Quasi-Newton Derivative-Free Optimization Method for Field Development Optimization. Society of Petroleum Engineers, Dubai, UAE. 2021. SPE 206267
27. Litvak M., Onwunali J., Baxter J. Field Development Optimization with Subsurface Uncertainties. Society of Petroleum Engineers, Colorado, USA. 2011. SPE 146512
28. Motlagh M., Thenon A. Automated Well Location Optimization Using Wish Technology. Society of Petroleum Engineers, Abu Dhabi, UAE. 2022. SPE 211621-MS
29. Kristoffersen B.S., Bellout M.C., Silva T.L., Berg F.C. An Automatic Well Planner for Complex Well Trajectories. Math Geosci. 2021, no. 53 (4). <https://doi.org/10.1007/s11004-021-09953-x>
30. Kristoffersen B.S., Bellout M.C., Silva T.L., Berg F.C. An Automatic Well Planner for Efficient Well Placement Optimization Under Geological Uncertainty. ECMOR XVII. 2020, no. 17. <https://doi.org/10.3997/2214-4609.202035211>
31. Abdul-Hameed M.R., Hamd-Allah S.M. Optimization sequence of infill well-drilling using Latin hypercube plus radial basis function network. Int. J. Nonlinear Anal. Appl. 2024, no. 15, pp. 87–96. <https://doi.org/10.22075/ijnaa.2023.29922.4296>
32. Zhang P., Gao T., Fu J., Li R. Deep-Learning-Based Approach for Optimizing Infill Well Placement. Society of Petroleum Engineers, San Antonio, Texas, USA. 2023. SPE 215072
33. Willigers B.J.A., Begg S., Bratvold R.B. Appraising Unconventional Resources: How Many Wells To Drill and Where To Place Them? Society of Petroleum Engineers. 2016. SPE 179736
34. Qadeer Siddiqui M.A., Khan R.A., Md Sarim J. Multi-objective Well Placement Optimization Considering Energy Sustainability Along With Economical Gains. Society of Petroleum Engineers, Cairo, Egypt. 2015. SPE 175842-MS
35. Sieberer M., Peisker J., Clemens T., Thiele M.R. Infill Well Portfolio Management under Uncertainty — Application to the 8TH Reservoir, Austria. Society of Petroleum Engineers, Paris, France. 2017. SPE 185803
36. Allard D.N., Hillyer M.G., Gerbacia W.E., Rychener L.M. Empirical Risk Assessment of Infill Drilling Locations, Barrow Island, Australia. Society of Petroleum Engineers, Houston, Texas, USA. 1999. SPE 56816
37. Bansal Y., Ertekin, T., Karpyn, Z., Ayala, L., Nejad, A. Forecasting Well Performance in a Discontinuous Tight Oil Reservoir Using Artificial Neural Networks. Society of Petroleum Engineers, The Woodlands, Texas, USA. 2013. SPE 164542
38. Колесов В.В., Курганов Д.В. Расчет рейтинга скважин-кандидатов при уплотняющем бурении с помощью машинного обучения на промысловых данных (метод опорных векторов) // Вестник Самарского государственного технического университета. Серия: Технические науки. — 2019. — № 1 (61).
39. Wang Z., Tang H., Cai H., Hou Y., Shi H., Li J., Yang T., Feng Y. Production prediction and main controlling factors in a highly heterogeneous sandstone reservoir: Analysis on the basis of machine learning. Energy Science & Engineering. 2022. <https://doi.org/10.1002/ese3.1297>

## References

1. Mata C., Saputelli L., Badmaev D., Zhao W., Mohan R., Gönczi D. Automated Reservoir Management Workflows to Identify Candidates and Rank Opportunities for Production Enhancement and Cost Optimization in a Giant Field in Offshore Abu Dhabi. Offshore Technology Conference, Houston, TX, USA. 2021. OTC 31295
2. Algarhy A., Bateman R.M., Soliman M.Y. An Innovative Technique To Evaluate Shale Sweetspots: A Case Study From North Africa. SPWLA 56th Annual Logging Symposium held in Long Beach, California, USA. July 18–22, 2015
3. Algarhy A., Ibrahim A.F., A. Gabry M., Ali Amr G. Predicting Shale Production Performance Through Machine Learning: The Development and Application of the Sweet Spot Quality Index. Society of Petroleum Engineers, Wheeling, West Virginia, USA. 2023. SPE 215911
4. Su Sh., Schulze-Riegert R., Mustapha H., Lang Ph., Kloucha Ch.K. Artificial Intelligence for Infill Well Placement and Design Optimization in Multi-layered/stacked Reservoirs Under Subsurface Uncertainty. Society of Petroleum Engineers, Abu Dhabi, UAE. 2021. SPE 207899
5. Pongtepupathum W., Lang Ph., Adeyemi T. An Ensemble-Based Infill Well Location Solution: A Cloud Native Application for Automating Well Placement and Evaluation. Society of Petroleum Engineers, Abu Dhabi, UAE. 2022. SPE 211361
6. Su Sh., Tahir S., Ghorayeb K., Ramatullayev S., Garcia-Teijeiro X. Multidisciplinary Data Integration for Artificial-Intelligence-Assisted Well Placement and Trajectory Design Optimization Under Uncertainty. Society of Petroleum Engineers, Abu Dhabi, UAE. 2022. SPE 211367
7. Bernadi B., Silalahi Eli S., Reksahutama A., Miraza D. Infill Wells Placement in High Water-Cut Mature Carbonate Field with Simulation Opportunity Index Method. Society of Petroleum Engineers, Bali, Indonesia. 2019. SPE 196388
8. Zijlstra E., Riethmuller G., Schäfftlein S., Mahruqi S. Using Marketing Technology in Reservoir Engineering: The Application of Data Driven Predictive Analysis on a Mature Oil Field. International Petroleum Technology Conference, Bangkok, Thailand. 2011. IPTC 14676
9. Al-Kinani A., Nunez G., Stundner M., Zangl G., Matta T., Cottone S. Selection of Infill Drilling Locations Using Customized Type Curves. Society of Petroleum Engineers, Cartagena, Columbia. 2019. SPE 122186
10. Aslanyan A., Kovalenko I., Ilyasov I., Gulyaev D., Buyanov A., Musaleev Kh. Waterflood study of high viscosity saturated reservoir with multiwell retrospective testing and cross-well pressure pulse-code testing. Society of Petroleum Engineers, Kuwait City, Kuwait. 2018. SPE-193712-MS

11. Aslanyan A., Asmadiyarov R., Kaeshkov I., Bikkulov M., Farakhova R., Krichevsky V., Gulyaev D., Musaleev Kh. *Multiwell deconvolution as important guideline to production optimisation: Western Siberia Case Study*. The International Petroleum Technology Conference, Beijing, China. 2019. IPTC-19566-MS
12. Aslanyan A., Grishko F., Krichevsky V., Gulyaev D., Panarina E., Buyanov A. *Assessing waterflood efficiency with deconvolution based multi-well retrospective test technique*. Society of Petroleum Engineers, London, England, UK. 2019. SPE195518-MS
13. Kovaleno I.V., Nemirovich G.M., Ilyasov I.R., Buyanov A.V., Gulyaev D.N. The usage of impulse-code interference technology during water flooding in difficult geological conditions. *Neftyanoe khozyaystvo*. June 2018. (In Russ.)
14. Sabzabadi A., Masoudi R., Arsanti D., Aslanyan I., Garnyshev M., Minakhmetova R., Karancharat R. *Verifying Local Oil Reserves Using Multi-Well Pressure Pulse Code Testing*. Off-shore Technology Conference Asia, Kuala Lumpur, Malaysia. 2018. OTC-28601-MS
15. Qin Zh., Xu T. *Shale gas geological "sweet spot" parameter prediction method and its application based on convolutional neural network*. Scientific Reports, Nature Portfolio, China. 2022. <https://doi.org/10.1038/s41598-022-19711-6>
16. Egorov D.V., Sabirov A.R. *Applying Machine Learning Methods to Search for Missing Net Pay Zones in Mature Oilfields Wells*. Society of Petroleum Engineers, Moscow, Russia. 2019. SPE 196869
17. Semenikhin A.S., Shchepetov A.A. *Missed Net Pay Zones in Mature Oilfields Via Injection of Expert Knowledge in Deep Learning Algorithms*. Society of Petroleum Engineers, Moscow, Russia. 2020. SPE 201922
18. Belozarov B., Bukhanov N. *Automatic Well Log Analysis Across Priobskoe Field Using Machine Learning Methods*. Society of Petroleum Engineers, Moscow, 2018. (In Russ.) SPE 191604-18RPTC-RU
19. Sakhnyuk V.I., Novikov E.V., Sharifullin A.M., Belokhin V.S., Antonov A.P. *Machine learning applications for well-logging interpretation of the Vikulov Formation*. Lomonosov Moscow State University, Moscow, 2022, vol. 24, № 2, pp. 230–238. (In Russ.) <https://doi.org/https://doi.org/10.18599/grs.2022.2.21>
20. Litvak M., Gane B., Williams G. *Field Development Optimization Technology*. Society of Petroleum Engineers, Houston. 2007. SPE 106426
21. Roussennac B., Gijs van Essen. *Streamlining the Well Location Optimization Process — An Automated Approach Applied to a Large Onshore Carbonate Field*. Society of Petroleum Engineers, Dubai, UAE. 2021. SPE 205913
22. Boah E.A., Senyo Kondo O.K., Borsah A.A. Critical Evaluation of Infill Well Placement and Optimization of Well Spacing Using the Particle Swarm Algorithm. *Journal of Petroleum Exploration and Production Technology*. 2019, no. 9 (4). <https://doi.org/10.1007/s13202-019-0710-1>
23. Ma Zh., Davani E., Ma X. *Finding a Trend Out of Chaos: A Machine-Learning Approach for Well-Spacing Optimization*. Society of Petroleum Engineers, Denver, Colorado, USA. 2020. SPE 201698
24. Li C., Fang Ch., Huang Y., Zuo H. *Infill well placement optimization for secondary development of waterflooding oilfields with SPFA algorithm*. *Frontiers in Energy Research*. 2022. <https://doi.org/10.3389/ferg.2022.1005749>
25. Forouzanfar F., Li G., Reynolds A.C. *A two-stage well placement optimization method based on adjoint gradient*. Society of Petroleum Engineers, Florence, Italy. 2010. SPE 135304
26. Alpak F., Wang Y., Gao G. *Benchmarking and Field-Testing of the Distributed Quasi-Newton Derivative-Free Optimization Method for Field Development Optimization*. Society of Petroleum Engineers, Dubai, UAE. 2021. SPE 206267
27. Litvak M., Onwunalu J., Baxter J. *Field Development Optimization with Subsurface Uncertainties*. Society of Petroleum Engineers, Colorado, USA. 2011. SPE 146512
28. Motlagh M., Thenon A. *Automated Well Location Optimization Using Wish Technology*. Society of Petroleum Engineers, Abu Dhabi, UAE. 2022. SPE 211621-MS
29. Kristoffersen B.S., Bellout M.C., Silva T.L., Berg F.C. An Automatic Well Planner for Complex Well Trajectories. *Math Geosci*. 2021, no. 53 (4). <https://doi.org/10.1007/s11004-021-09953-x>
30. Kristoffersen B.S., Bellout M.C., Silva T.L., Berg F.C. An Automatic Well Planner for Efficient Well Placement Optimization Under Geological Uncertainty. *ECMOR XVII*. 2020, no. 17. <https://doi.org/10.3997/2214-4609.202035211>
31. Abdul-Hameed M.R., Hamd-Allah S.M. Optimization sequence of infill well-drilling using Latin hypercube plus radial basis function network. *Int. J. Nonlinear Anal. Appl.* 2024, no. 15, pp. 87–96. <https://doi.org/10.22075/ijnaa.2023.29922.4296>
32. Zhang P., Gao T., Fu J., Li R. *Deep-Learning-Based Approach for Optimizing Infill Well Placement*. Society of Petroleum Engineers, San Antonio, Texas, USA. 2023. SPE 215072
33. Willigers B.J.A., Begg S., Bratvold R.B. *Appraising Unconventional Resources: How Many Wells To Drill and Where To Place Them?*. Society of Petroleum Engineers. 2016. SPE 179736
34. Qadeer Siddiqui M.A., Khan R.A., Md Sarim J. *Multi-objective Well Placement Optimization Considering Energy Sustainability Along With Economical Gains*. Society of Petroleum Engineers, Cairo, Egypt. 2015. SPE 175842-MS
35. Sieberer M., Peisker J., Clemens T., Thiele M.R. *Infill Well Portfolio Management under Uncertainty — Application to the 8TH Reservoir, Austria*. Society of Petroleum Engineers, Paris, France. 2017. SPE 185803
36. Allard D.N., Hillyer M.G., Gerbacia W.E., Rychener L.M. *Empirical Risk Assessment of Infill Drilling Locations, Barrow Island, Australia*. Society of Petroleum Engineers, Houston, Texas, USA. 1999. SPE 56816
37. Bansal Y., Ertekin, T., Karpyn, Z., Ayala, L., Nejad, A. *Forecasting Well Performance in a Discontinuous Tight Oil Reservoir Using Artificial Neural Networks*. Society of Petroleum Engineers, The Woodlands, Texas, USA. 2013. SPE 164542
38. Kolesov V. V., Kurganov D. V. Well ranking for in-fill drilling using machine learning with production and geological data. *Samara State Technical University. Series: Technical Sciences*. 2019, no. 1 (61). (In Russ.)
39. Wang Z., Tang H., Cai H., Hou Y., Shi H., Li J., Yang T., Feng Y. Production prediction and main controlling factors in a highly heterogeneous sandstone reservoir: Analysis on the basis of machine learning. *Energy Science & Engineering*. 2022. <https://doi.org/10.1002/ese3.1297>

## ВКЛАД АВТОРОВ / AUTHOR CONTRIBUTIONS

**А.А. Прохоров** — оказал экспертную и методологическую поддержку при разборе и оценке методик, окончательно утвердил публикуемую версию статьи.

**А.Ф. Мурзакова** — разработала концепцию статьи в части методик по поиску зон через картопостроение и через обнаружение пропущенных интервалов, подготовила текст статьи.

**Andrey A. Prokhorov** — provided expert and methodological support in the analysis and evaluation of the methods, and finally approved the published version of the article.

**Alina F. Murzakova** — developed the article's concept regarding methods for locating zones through map construction and detection of missed intervals, and prepared the article's text.

**А.А. Рыбаковская** — разработала концепцию статьи в части обзора методик по оптимальному расположению фонда в новых зонах и экономической оценки, подготовила текст статьи.

**Д.Н. Сазонов** — оказал экспертную и методологическую поддержку при разборе и оценке методик.

**Anastasia A. Rybakovskaya** — developed the article's concept regarding the review of methods for optimal placement of the fund in new zones and economic evaluation, and prepared the article's text.

**Dmitry N. Sazonov** — provided expert and methodological support in the analysis and evaluation of the methods.

## СВЕДЕНИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Андрей Александрович Прохоров\*** — руководитель проекта по разработке продуктов, Группа компаний «Газпром нефть»  
190000, Россия, г. Санкт-Петербург,  
ул. Почтамтская, д. 3–5.  
e-mail: ProNeft@gazprom-neft.ru

**Алина Фанисовна Мурзакова** — главный специалист, Санкт-Петербургский политехнический университет Петра Великого

**Анастасия Андреевна Рыбаковская** — главный специалист, Национальный исследовательский Томский политехнический университет

**Дмитрий Николаевич Сазонов** — руководитель проекта по разработке продукта, Группа компаний «Газпром нефть»

**Andrey A. Prokhorov\*** — Product development manager, Gazprom нефт company group  
3–5, Pochtamtskaya str., 190000, Saint Petersburg, Russia.  
e-mail: ProNeft@gazprom-neft.ru

**Alina F. Murzakova** — Chief specialist, Peter the Great Saint Petersburg Polytechnic University

**Anastasia A. Rybakovskaya** — Chief specialist, National Research Tomsk Polytechnic University

**Dmitry N. Sazonov** — Product development project manager, Gazprom нефт company group

\* Автор, ответственный за переписку / Corresponding author