

Научная статья / Original research article
УДК 681.3:622.276.6
DOI: <https://doi.org/10.31660/0445-0108-2026-2-64-73>
EDN: HFYDLJ



Применение технологий машинного обучения для подбора скважин-кандидатов на проведение гидравлического разрыва пласта

А. В. Малышева

Альметьевский государственный технологический университет «Высшая школа нефти», Альметьевск, Российская Федерация
nastyamalysheva9566@gmail.com

Аннотация. В условиях истощения легкодоступных запасов углеводородов в России высокую значимость приобретает оптимизация методов интенсификации притока, в частности гидравлического разрыва пласта. Основная проблема традиционного подхода к подбору скважин-кандидатов заключается в субъективности экспертных оценок и неспособности классических табличных критериев учитывать скрытые нелинейные зависимости между геолого-техническими параметрами. Цель работы — разработка и апробация интеллектуальной системы прогнозирования эффективности ГРП на основе больших данных. Ведущим методом исследования выступает машинное обучение, реализованное через гибридную архитектуру нейронных сетей. Предложенная модель сочетает полносвязные слои для обработки статических характеристик пласта и рекуррентные блоки типа LSTM для анализа динамических временных рядов добычи. В качестве эмпирической базы использованы сведения о более чем 2 000 операциях ГРП. Результаты исследования демонстрируют преимущество предложенного алгоритма над традиционными методами: точность классификации успешных операций увеличилась с 56 до 70 %. Модель показала высокую устойчивость при ранжировании объектов по потенциалу продуктивности, даже при наличии погрешностей в количественном прогнозе дебита. Практическая значимость работы заключается в создании эффективного инструмента поддержки принятия решений, позволяющего минимизировать риски неэффективных капиталовложений и автоматизировать процесс предварительного отбора скважин. Внедрение подобных систем способствует цифровой трансформации нефтегазовой отрасли в рамках концепции «Индустрия 4.0».

Ключевые слова: гидравлический разрыв пласта, машинное обучение, отбор скважин-кандидатов, прогнозирование эффективности, гибридная модель

Для цитирования: Малышева А. В. Применение технологий машинного обучения для подбора скважин-кандидатов на проведение гидравлического разрыва пласта. *Известия высших учебных заведений. Нефть и газ.* 2026;30(2):64–73. <https://doi.org/10.31660/0445-0108-2026-2-64-73> EDN: HFYDLJ

Application of machine learning technologies for the candidate-wells selection for hydraulic fracturing

Anastasia V. Malysheva

Almetyevsk State Technological University "Petroleum Higher School", Almetyevsk, Russian Federation
nastyamalysheva9566@gmail.com

Abstract. In the face of dwindling easily hydrocarbon reserves in Russia, optimization methods of stimulation inflow, specifically hydraulic fracturing, has become critically important. Unfortunately, traditional approach of candidate-well selection features the high subjectivity of expert assessment and the inability of conventional tabular criteria to account for hidden non-linear relationships between geological and technical parameters. Therein lies the key problem with it. This article aims to develop and validate an intelligent system for predicting hydraulic fracturing efficiency based on Big Data. The study uses machine learning implemented through a hybrid neural network architecture as a leading method. The proposed model combines fully connected layers for processing static reservoir characteristics with Long Short-Term Memory (LSTM) recurrent blocks for analysis of dynamic production time series. The empirical database includes data from over 2,000 hydraulic fracturing operations. The results of this study demonstrate that proposed algorithm has an advantage over traditional methods: the accuracy of classifying successful operations increased from 56% to 70%. The model showed high robustness in ranking objects by productivity potential, even with minor discrepancies in quantitative flow rate forecasting. The practical significance of this work lies in providing an effective decision-support tool. This tool will minimize the risks of inefficient investments and automates the pre-selection process. The implementation of such systems facilitates the digital transformation of the oil and gas industry within the "Industry 4.0" framework.

Keywords: hydraulic fracturing, machine learning, candidate well selection, efficiency forecasting, hybrid model

For citation: Malysheva A. V. Application of machine learning technologies for the candidate-wells selection for hydraulic fracturing. *Oil and Gas Studies*. 2026;30(2):64–73. (In Russ.). <https://doi.org/10.31660/0445-0108-2026-2-64-73>

Введение

Нефтегазовая отрасль традиционно играет ключевую роль в экономике Российской Федерации. В условиях постепенного истощения легкодоступных запасов углеводородов особое значение приобретают технологии, обеспечивающие повышение эффективности добычи и переработки сырья. Среди них особое место занимает гидравлический разрыв пласта (ГРП) — метод интенсификации притока, многократно доказавший свою результативность на практике [1].

Сегодня ГРП относится к числу наиболее востребованных и обсуждаемых технологий в нефтедобыче. Его применение позволяет не только поддерживать уровень добычи на зрелых месторождениях, но и повышать конечный коэффициент извлечения нефти, вовлекать в разработку трудноизвлекаемые залежи, эксплуатация которых ранее считалась экономически нецелесообразной [2]. Тем самым обеспечивается более быстрая окупаемость вложенных инвестиций.

Однако эффективность ГРП во многом зависит от корректного выбора скважин-кандидатов. На практике даже при соблюдении технологических требований результаты операций могут различаться в несколько раз. Основной причиной неудач часто становится недостаточная проработка этапа планирования и анализа исходных данных [3]. Математическое моделирова-

ние процесса позволяет частично снизить эти риски, однако классические модели имеют свои ограничения [4].

Отбор скважин для проведения ГРП традиционно осуществляется на основе экспертных оценок специалистов и накопленного промыслового опыта [5]. Несмотря на наличие статистики по проведенным операциям, этот процесс остается во многом субъективным. Разные инженерные группы нередко приходят к противоположным выводам, поскольку критерии подбора зависят от опыта и интуиции экспертов, а также от специфики конкретного месторождения (рис. 1) [6, 7].



Рис. 1. Структурная схема классического способа подбора скважин-кандидатов
Fig. 1. Structural diagram of the classical method for selecting candidate wells

Как правило, критерии представляют собой таблицы с перечнем параметров и их граничными значениями: проницаемость, дебит, давление, обводненность, характеристики пласта [8]. Эти таблицы периодически корректируются в ходе опытно-промышленных работ. Тем не менее, ручная обработка большого объема данных приводит к потерям информации и повышает риск ошибок.

Практика показывает, что нередко скважины, полностью удовлетворяющие установленным критериям, демонстрируют слабый эффект после ГРП, в то время как некоторые «нетипичные» объекты дают высокий прирост добычи. Это указывает на то, что традиционные методы не учитывают сложные взаимосвязи между множеством факторов, влияющих на результат [9].

Современные тенденции цифровизации промышленности, объединенные понятием «Индустрия 4.0», открывают новые возможности для оптимизации производственных процессов в нефтегазовой сфере [10]. Среди ключевых инструментов цифровой трансформации особое место занимают Big Data и машинное обучение — технологии, позволяющие

анализировать большие массивы информации и выявлять закономерности, неочевидные для человека [11].

Машинное обучение уже активно применяется для решения различных задач: прогнозирования отказов оборудования, оптимизации режимов эксплуатации, анализа сейсмических данных или прогнозирования пластового давления [12]. В контексте ГРП эти методы позволяют строить модели, способные прогнозировать эффективность операций на основе исторических данных, учитывать геолого-технические параметры и тем самым снижать неопределенность при выборе скважин-кандидатов [13].

Объект и методы исследования

Успешное применение машинного обучения представляет собой циклический процесс, а не разовую задачу. Его жизненный цикл включает несколько ключевых этапов: от сбора и подготовки данных до развертывания обученной модели и мониторинга ее работы в реальных условиях, с последующей обратной связью для улучшения (рис. 2) [14]. Эта итеративная процедура обеспечивает постоянное повышение точности и надежности прогнозов.




Рис. 2. Жизненный цикл машинного обучения

Fig. 2. Machine learning lifecycle

Основным условием успешного внедрения ML является наличие качественных и репрезентативных данных. Например, в ПАО «Татнефть» за период 1996–2016 гг. было проведено более 1 700 операций ГРП на различных объектах, что создало обширную базу для аналитических исследований и обучения моделей [15].

Алгоритмы машинного обучения (в частности, градиентный бустинг, случайный лес, нейронные сети) способны учитывать десятки и сотни

признаков — от геологических характеристик до истории эксплуатации и экономических параметров [16]. Обученные модели выявляют скрытые зависимости и ранжируют скважины по вероятности достижения целевого прироста дебита.

Одно из ключевых преимуществ ML-подхода — его объективность и масштабируемость: модель способна анализировать тысячи записей и обновлять прогноз при поступлении новых данных. Кроме того, методы интерпретации моделей (например, SHAP, LIME) позволяют инженерам видеть вклад каждого параметра в итоговое решение, что делает процесс прозрачным и повышает доверие специалистов [17].

Использование машинного обучения в процессе подбора скважин дает ряд ощутимых преимуществ, начиная с повышения точности прогнозов и снижения числа неэффективных операций и заканчивая выявлением новых закономерностей, ранее не описанных традиционными моделями.

Тем не менее остаются и вызовы. Среди них — неполнота данных, различие форматов информации с разных месторождений, а также необходимость согласования ML-подходов с существующими инженерными процедурами. Важно понимать, что машинное обучение не заменяет опыт эксперта, а служит инструментом поддержки принятия решений, повышающим точность и обоснованность прогнозов [18]. В некоторых случаях целесообразно совмещать ML с методами моделирования кислотного ГРП для расширения области применения [19].

В перспективе развитие ML-технологий в нефтегазовой отрасли идет в сторону интеграции с системами цифровых двойников месторождений, что позволит непрерывно обновлять прогнозы в реальном времени. Также активно развиваются гибридные подходы, объединяющие физические модели с алгоритмами машинного обучения.

Переход от экспертных оценок к автоматизированным системам подбора скважин-кандидатов на ГРП — это важный шаг к созданию умных систем управления разработкой месторождений, где каждое решение обосновывается данными, а не только интуицией инженера.

В рамках исследования использована база данных, включающая сведения о более чем 2 000 операциях ГРП, проведенных на месторождениях компании ПАО «Гатнефть». Каждая запись содержала как статические геолого-технические характеристики, так и динамические данные о добыче нефти и воды по месяцам до проведения операции.

Для прогнозирования результативности ГРП были выделены 3 укрупненные группы факторов:

1. Размеры и глубина пласта — отражают геометрические параметры продуктивных интервалов.
2. Фильтрационно-емкостные свойства — характеризуют проницаемость, пористость и насыщенность пласта.

3. Показатели добычи углеводородов и воды — позволяют оценить текущее состояние разработки и динамику изменения дебита.

Целевая переменная определялась как прирост дебита нефти после проведения операции относительно исходных значений.

Для решения задачи прогнозирования была разработана архитектура модели, сочетающая преимущества традиционных нейронных сетей и анализа временных рядов. Поскольку в наборе данных присутствуют как статические признаки, так и временные зависимости (добыча по месяцам до ГРП), было принято решение объединить в одной архитектуре два подхода:

- обработка статических признаков через полносвязные слои;
- анализ временных рядов с помощью рекуррентной нейронной сети типа LSTM [20].

Такое решение позволило учесть не только физико-геологические характеристики скважин, но и динамику изменений их работы, что существенно повысило точность прогноза. Обучение модели проводилось на исторических данных с разделением выборки на обучающую и тестовую части в соотношении 80/20. Качество модели оценивалось по точности классификации успешных операций.

Результаты

Сравнение результатов моделирования с традиционным экспертным отбором показало, что предложенная модель значительно повышает качество прогнозов. При тестировании модель правильно определила успешность с точностью около 70 %, в то время как при традиционном подходе корректно классифицировались 56 % скважин.

Таким образом, применение машинного обучения позволяет увеличить долю успешных операций на 14 %. Это подтверждает, что даже при ограниченной точности количественного прогноза дебита модель надежно ранжирует объекты по потенциалу, выделяя наиболее перспективные для проведения ГРП.

Несмотря на то, что модель периодически занижает прогнозируемый дебит относительно фактического, наблюдается устойчивая зависимость: скважины с более высоким потенциалом в реальности получают и более высокие прогнозные значения. Это делает модель надежным инструментом ранжирования и предварительного отбора, даже в случаях частичного расхождения с реальными значениями дебита.

Выводы

Предложенная система служит не только средством количественного прогнозирования, но и эффективным инструментом поддержки принятия решений. Применение модели также позволяет уменьшить долю неэффективных ГРП, сократить время на анализ данных и повысить

экономическую отдачу за счет выбора наиболее перспективных объектов для проведения гидравлического разрыва пласта.

Проведенное исследование показало, что использование методов машинного обучения при планировании операций ГРП обеспечивает значительное повышение точности прогнозирования эффективности и позволяет оптимизировать процесс выбора скважин. Даже при определенных погрешностях в оценке абсолютных значений дебита модель демонстрирует устойчивую способность идентифицировать наиболее перспективные объекты, что делает ее ценным инструментом практического применения. Внедрение подобных интеллектуальных систем в производственную практику создает предпосылки для перехода к данным управляемой модели нефтедобычи, где решения принимаются на основе объективного анализа и цифровых технологий.

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.
Conflict of interests. The author declares no conflicts of interest.

Список источников

1. Садыков Г. М., Гладкова П. О., Гайдамакин Д. Н. Применение метода гидравлического разрыва пласта для повышения нефтеотдачи. *Инновационная наука*. 2021;(12-2):34–36.
2. Бисембаева К. Т., Джалалов Г. И., Сабырбаева Г. Оценка эффективности гидроразрыва пласта на нефтяном месторождении. *Yessenov science journal*. 2022;2(43):125–133. <https://doi.org/10.56525/CVZE7367>
3. Бобков Д. О. Проблемы, возникающие при проведении ГРП, и возможности их решения. *Современные научные исследования и инновации*. 2017;(7):41–46.
4. Есипов Д. В., Куранаков Д. С., Лапин В. Н., Чёрный С. Г. Математические модели гидроразрыва пласта. *Вычислительные технологии*. 2014;19(2):33–61.
5. Рамазанов Р. Р., Харламов К. А., Летко И. И., Марценюк Р. А. Анализ эффективности геолого-технических мероприятий. *Нефтяное хозяйство*. 2019;(6):62–65. <https://doi.org/10.24887/0028-2448-2019-6-62-65>.
6. Киселев К. А. Критерии подбора скважин-кандидатов для операции многостадийного гидроразрыва пласта. *Вестник науки*. 2020;2(1-22):203–206.
7. Салимов О. В., Насыбуллин А. В., Сахабутдинов Р. З., Салимов В. Г. О критериях подбора скважин для гидроразрыва пласта. *Георесурсы*. 2017;19(4):368–373.
8. Фархутдинова М. *Анализ влияния параметров скважин и процесса ГРП на его эффективность*. Москва: LAP Lambert Academic Publishing; 2014. 52 с.
9. Стромилло Д. В., Ахымбаева Б. С. Геологические факторы и современные подходы к гидроразрыву пласта. *Вестник науки*. 2024;5(12-2):418–425.
10. Попов Е. А., Стариков М. А., Невкин А. А. Внедрение алгоритмов машинного обучения в производственные процессы компаний нефтяной и газовой промышленности. *Бурение и нефть*. 2021;(4):36–40.

11. Надршин И. Р. Внедрение искусственного интеллекта в процесс подготовки и проведения гидроразрыва пласта. *Молодые нефтяники*. 2025;(IX):219–222. <https://doi.org/10.24412/cl-37425-2025-1-219-222>
12. Мартюшев Д. А., Пономарева И. Н., Захаров Л. А., Шадров Т. А. Применение машинного обучения для прогнозирования пластового давления при разработке нефтяных месторождений. *Известия Томского политехнического университета. Инжиниринг георесурсов*. 2021;332(10):140–149. <https://doi.org/10.18799/24131830/2021/10/3401>
13. Азбуханов А. Ф., Костригин И. В., Бондаренко К. А., Семенова М. Н., Середа И. А., Юлмухаметов Д. Р. Подбор скважин-кандидатов для проведения гидроразрыва пласта на основе математического моделирования с использованием методов машинного обучения. *Нефтяное хозяйство*. 2019;(11):38–42. <https://doi.org/10.24887/0028-2448-2019-11-38-42>
14. Кочнев А. А., Козырев Н. Д., Кочнева О. Е., Галкин С. В. Разработка комплексной методики прогноза эффективности геолого-технических мероприятий на основе алгоритмов машинного обучения. *Георесурсы*. 2020;22(3):79–86. <https://doi.org/10.18599/grs.2020.3.79-86>
15. Дуткин А. С., Алаева Н. Н. Подбор параметров для прогнозирования результативности гидравлического разрыва пласта. *Достижения, проблемы и перспективы развития нефтегазовой отрасли 2024: материалы IX Международной научно-практической конференции*. Альметьевск: Альметьевский государственный технологический университет «Высшая школа нефти»; 2024. С. 685–689.
16. Галкин В. И., Колтырин А. Н. Исследование вероятностных моделей для прогнозирования эффективности технологии пропантного гидравлического разрыва пласта. *Записки Горного института*. 2020;(246):650–659. <https://doi.org/10.31897/PMI.2020.6.7>
17. Мухтаруллин И. Ф., Ябиров Р. З., Владимиров В. В. Прогноз уровня добычи и оценка эффективности геолого-технических мероприятий на основе аналитических методов. *Георесурсы*. 2010;1(33):42–43.
18. Загитова Л. Р., Дуткин А. С., Рассказова А. А. Разработка методики прогнозирования результативности гидравлического разрыва пласта с применением алгоритмов машинного обучения. *Научно-технический вестник Поволжья*. 2024;(4):36–40.
19. Каневская Р. Д., Новиков А. В. Методы моделирования кислотного гидроразрыва пласта. *Автоматизация, телемеханизация и связь в нефтяной промышленности*. 2018;(3):28–34. <https://doi.org/10.30713/0132-2222-2018-3-28-34>
20. Андронов Ю. В., Стрекалов А. В. Выбор переменных для обучения нейронной сети при прогнозировании эффективности гидравлического разрыва пласта. *Нефтегазовое дело*. 2014;12(3):37–47.

References

1. Sadykov G. M., Gladkova P. O., Gaidamakin D. N. Application of hydraulic fracturing to enhance oil recovery. *Innovative science*. 2021;(12-2):34–36. (In Russ.).
2. Bissebayeva K. T., Dzhalalov G. I., Sabyrbayeva G. Efficiency estimation of hydraulic fracturing at oil deposit. *Yessenov science journal*. 2022. №2 (43). 2022;2(43):125–133. (In Russ.). <https://doi.org/10.56525/CBZE7367>
3. Bobkov D. O. Problems arising during hydraulic fracturing and the possibilities of their solution. *Modern scientific research and innovation*. 2017;(7): 41–46. (In Russ.).

4. Esipov D. V., Kuranakov D. S., Lapin V. N., Cherny S. G. Mathematical models of hydraulic fracturing. *Computational technologies*. 2014;19(2):33–61.
5. Ramazanov R. R., Kharlamov K. A., Letko I. I., Martsenyuk R. A. Efficiency analysis of geological and technical measures. *Oil industry*. 2019;(6):62–65. (In Russ.). <https://doi.org/10.24887/0028-2448-2019-6-62-65>
6. Kiselev K. A. Criteria for selecting candidate wells for multistage hydraulic fracturing operations formation. *Science Bulletin*. 2020;2(1-22):203–206. (In Russ.).
7. Salimov O. V., Nasybullin A. V., Sakhabutdinov R. Z., Salimov V. G. The criteria for the selection of wells for hydraulic fracturing. *Georesourcy*. 2017;19(4):368–373. (In Russ.).
8. Farkhutdinova M. Analysis of the influence of well parameters and the hydraulic fracturing process on its efficiency. Moscow: LAP Lambert Academic Publishing; 2014. (In Russ.).
9. Stromilo D. V., Akhimbaeva B. S. Geological factors and modern approaches to hydraulic fracturing. *Science Bulletin*. 2024;5(12-2):418–425.
10. Popov E. A., Starikov M. A., Nevkin A. A. Implementation of machine learning algorithms in the production processes of companies in the oil and gas industry. *Drilling and Oil*. 2021;(4):36–40. (In Russ.).
11. Nadrshin I. R. The introduction of artificial intelligence in the process of preparation and conduct of hydraulic fracturing. *Molodye neftyaniki*. 2025;(IX): 219–222. (In Russ.). <https://doi.org/10.24412/cl-37425-2025-1-219-222>
12. Martyushev D. A., Ponomareva I. N., Zakharov L. A., Shadrov T. A. Application of machine learning for forecasting formation pressure in oil field development. *Bulletin of the Tomsk polytechnic university. Geo assets engineering*. 2021;332(10):140–149. (In Russ.). <https://doi.org/10.18799/24131830/2021/10/3401>
13. Azbukhanov A. F., Kostigrin I. V., Bondarenko K. A., Semenova M. N., Sereda I. A., Yulmukhametov D. R. Selection of wells for hydraulic fracturing based on mathematical modeling using machine learning methods. *Oil industry*. 2019;(11):38–42. (In Russ.). <https://doi.org/10.24887/0028-2448-2019-11-38-42>
14. Kochnev A. A., Kozyrev N. D., Kochneva O. E., Galkin S. V. Development of a comprehensive methodology for the forecast of effectiveness of geological and technical measures based on machine learning algorithms. *Georesourcy*. 2020;22(3):79–86. (In Russ.). <https://doi.org/10.18599/grs.2020.3.79-86>
15. Dutkin A. S., Alayeva N. N. Selection of parameters for predicting the effectiveness of hydraulic fracturing. *Achievements, problems and prospects of the oil and gas industry development in 2024: proceedings of the IX International Scientific and Practical Conference*. Almet'yevsk: Almet'yevsk State Technological University "Higher School of Petroleum"; 2024, pp. 685–689. (In Russ.).
16. Galkin V. I., Koltyrin A. N. Investigation of probabilistic models for forecasting the efficiency of proppant hydraulic fracturing technology. *Journal of mining institute*. 2020;(246):650–659. (In Russ.). <https://doi.org/10.31897/PMI.2020.6.7>
17. Mukhtarullin I. F., Yabirov R. Z., Vladimirov V. V. Prediction of oil production and workover effectiveness estimation on basis of analytical methods. *Georesourcy*. 2010;1(33):42–43. (In Russ.).
18. Zagitova L. R., Dutkin A. S., Rasskazova A. A. Development of a method for predicting the performance of hydraulic fracturing using machine learning algorithms. *Scientific and Technical Volga region Bulletin*. 2024;(4):36–40. (In Russ.).

19. Kanevskaya R. D., Novikov A.V. Methods of modeling acid hydraulic fracturing. *Automation, telemechanization and communication in oil industry*. 2018;(3):28–34. (In Russ.). <https://doi.org/10.30713/0132-2222-2018-3-28-34>

20. Andronov Yu. V. Strekalov A. V. Choice of variables for neural network training for predicting the efficiency of formation hydraulic fracturing. *Petroleum engineering*. 2014;12(3):37–47. (In Russ.).

Информация об авторе / Information about the author

Малышева Анастасия Владимировна, студент, член рабочей группы 3D сканирования специального конструкторско-технологического бюро, Альметьевский государственный технологический университет «Высшая школа нефти», г. Альметьевск, nastyamalysheva9566@gmail.com

Anastasia V. Malysheva, Student, Member of the 3D Scanning Working Group of the Special Design and Technology Bureau, Almet'yevsk State Technological University "Petroleum Higher School", Almet'yevsk

Поступила в редакцию / Received 16.10.2025

Поступила после рецензирования / Revised 21.11.2025

Принята к публикации / Accepted 05.03.2026