

Научная статья
УДК 004.032.26
DOI: <https://doi.org/10.18127/j20700970-202503-10>

Оценка влияния геологических характеристик на нефтеотдачу пласта с применением нейронных сетей

Э.Н. Рамазанова¹

¹ Финансовый университет при Правительстве Российской Федерации (Москва, Россия)

¹ Московский государственный технический университет им. Н.Э. Баумана (Москва, Россия)

¹ enramazanova@fa.ru

Аннотация

Постановка проблемы. Геологические характеристики месторождений оказывают значительное влияние на выбор и применение технологий добычи нефти. Их правильная оценка может способствовать оптимизации этих процессов. Использование алгоритмов машинного обучения позволяет более точно прогнозировать и анализировать взаимосвязь между геологическими параметрами и эффективностью технологий добычи, что, в свою очередь, может привести к повышению производительности и снижению затрат. В связи с этим необходимо провести оценку влияния геологических характеристик на нефтеотдачу пласта с использованием методов машинного обучения.

Цель. Разработать нейронную сеть, способную анализировать геологические данные и предсказывать их влияние на нефтеотдачу пласта.

Результаты. Создана и обработана база данных с геологическими характеристиками нефтяных месторождений. Разработана и обучена нейронная сеть на основе предоставленных геологических данных для прогнозирования нефтеотдачи пласта. Проведен анализ влияния отдельных геологических характеристик на производительность нефтяного пласта. Выявлены ключевые факторы, влияющие на нефтеотдачу пласта, и дана оценка их значимости.

Практическая значимость. Проведенные исследования показали возможность улучшения прогнозирования нефтеотдачи пласта с помощью использования нейронных сетей. Разработка такой модели позволит эффективнее управлять процессом добычи нефти, оптимизировать работы на месторождениях, а также снизить операционные затраты и повысить эффективность добычи углеводородов.

Ключевые слова

Пласт, вязкость, плотность, нефтеотдача, машинное обучение, нейронные сети

Для цитирования

Рамазанова Э.Н. Оценка влияния геологических характеристик на нефтеотдачу пласта с применением нейронных сетей // Нелинейный мир. 2025. Т. 23. № 3. С. 81–87. DOI: <https://doi.org/10.18127/j20700970-202503-10>

A brief version in English is given at the end of the article

Введение

Актуальность исследования влияния геологических характеристик на нефтеотдачу пласта обусловлена необходимостью повышения эффективности разработки нефтяных месторождений. Нефтеотдача пласта – один из ключевых показателей, определяющих рентабельность и экономическую эффективность нефтедобычи. Однако на нефтедобычу оказывает влияние множество факторов, связанных с геологическими особенностями пласта, например, пористость, проницаемость, плотность, неоднородность, вязкость нефти и др. Понимание и количественная оценка влияния этих факторов имеют важное значение для оптимизации технологических решений, применяемых на различных этапах разработки.

Традиционно для оценки нефтеотдачи пласта используются аналитические модели, основанные на законах физики, гидродинамики и геологии. Примерами таких методов являются модели Дарси, Бакли–Левретта, Маскета–Мерсера и др. Данные модели позволяют прогнозировать динамику извлечения нефти в зависимости от пластовых характеристик. Однако они имеют ограниченную применимость и требуют значительного упрощения реальных геологических условий [1–4].

В этой связи применение современных методов искусственного интеллекта (в частности, нейронных сетей) открывает новые возможности для более адекватного моделирования и прогнозирования нефтеотдачи пласта [5–8].

Ц е л ь р а б о т ы – разработать нейронную сеть, способную анализировать геологические данные и предсказывать их влияние на нефтеотдачу пласта.

Нейронные сети способны выявлять сложные нелинейные зависимости между входными геологическими параметрами и выходными характеристиками пласта, что позволяет повысить точность оценки нефтеотдачи [9]. Применение нейронных сетей в геологических исследованиях доказало свою эффективность при решении задач литологического моделирования, прогнозирования свойств пород – коллекторов, интерпретации данных геоинформационной системы (ГИС) и др.

Таким образом, разработка методики оценки влияния геологических характеристик на нефтеотдачу пласта с применением нейронных сетей является актуальной научной задачей, решение которой позволит повысить эффективность разработки нефтяных месторождений.

Методология

Существует ряд традиционных методов оценки нефтеотдачи, основанных на анализе геологических, геофизических и промысловых данных. Среди них можно выделить три метода [10, 11]:

1. *Методы на основе геолого-физических моделей пласта.* Данные методы предполагают построение детальных геолого-физических моделей пласта с учетом таких параметров, как пористость, проницаемость, насыщенность, толщина и т.д. На основе этих моделей производится расчет потенциальной нефтеотдачи.

2. *Методы на основе корреляционного анализа.* Эти методы основаны на установлении корреляционных зависимостей между нефтеотдачей и комплексом геолого-физических параметров пласта. Полученные корреляционные модели используются для прогноза нефтеотдачи.

3. *Методы на основе статистического анализа.* В рамках данных методов применяются различные статистические техники, такие как регрессионный анализ, для установления зависимостей между нефтеотдачей и геолого-физическими параметрами.

В последние годы все большее распространение получают методы, основанные на применении искусственных нейронных сетей. Процесс построения модели оценки нефтеотдачи с применением нейронных сетей включает в себя следующие основные этапы.

Э т а п 1. *Сбор и подготовка геологических данных.* Проводится сбор необходимых геолого-физических параметров пласта, таких как пористость, проницаемость, насыщенность, толщина и т.д. Данные могут быть получены из различных источников, включая геологические отчеты, результаты лабораторных исследований керна, промысловые данные.

Э т а п 2. *Предварительная обработка данных.* Производится очистка и нормализация данных, удаление выбросов, заполнение пропусков. Данные подготавливаются для последующего применения их в нейронной сети.

Э т а п 3. *Разработка архитектуры нейронной сети.* Выбирается оптимальная архитектура нейронной сети, включающая в себя количество скрытых слоев, число нейронов в каждом слое, функции активации и т.д. Эти параметры подбираются итеративно на основе экспериментов.

Э т а п 4. *Обучение и валидация нейронной сети.* Нейронная сеть обучается на части имеющихся данных, а ее эффективность оценивается на оставшейся части данных (валидационная выборка). Процесс обучения и валидации повторяется до достижения требуемой точности модели.

Э т а п 5. *Применение обученной модели для оценки нефтеотдачи.* Обученная нейронная сеть используется для прогнозирования нефтеотдачи на основе геологических характеристик пласта.

Применение нейронных сетей позволяет учитывать сложные нелинейные взаимосвязи между геологическими параметрами и нефтеотдачей, что повышает точность оценки по сравнению с традиционными методами. Кроме того, нейронные сети обладают способностью к обобщению, что позволяет применять их для прогноза нефтеотдачи на новых участках месторождений.

Эксперименты и их результаты

Для создания нейронной сети были использованы фреймворк Tensorflow, библиотека Keras, а также язык программирования Python [12].

Сначала производится загрузка данных и преобразование значений в значения с плавающей запятой, поскольку именно этот тип данных более подходит для организации работы нейронной сети.

Затем выполняется масштабирование данных в диапазоне от 0 до 1. Для этого использован класс предварительной обработки MinMaxScaler из библиотеки scikit-learn

Упорядоченный набор данных разделен на учебный и тестовый. Разделение производилось на каждой итерации обучения при помощи функции train_test_split с 67% наблюдений для обучения модели и 33% для тестирования модели

Для подготовки набора данных определена специальная функция, которая принимает два аргумента: целиком набор данных и число шагов, которые будут использоваться как входные параметры для прогноза. При помощи такой функции производится подготовка набора данных для обучения, а также для тестирования нейронной сети. Затем происходит преобразование их в структуру, которая соответствует входу нейронной сети.

В коде настройки организован слой с четырьмя блоками LSTM, а также выходной уровень, который возвращает одно значение. Для нейронов сети применена сигмоидальная функция активации, обучение сети производится в течение 100 эпох. Результаты обучения модели представлены на рис. 1. Качество модели оценивается на учебном и тестовом наборе данных.

Для оценивания важности анализируемых геологических параметров разработанные модели были апробированы для каждого из параметров отдельно. Результаты моделирования представлены на рис. 2–10.




Рис. 1. Пример обучения модели

Fig. 1. Model training example




Рис. 2. Результаты моделирования зависимости коэффициента нефтеотдачи и вязкости нефти с шагом 1 и метрики модели

Fig. 2. Results of modeling the dependence of oil recovery factor and oil viscosity with step 1 and model metrics




Рис. 3. Результаты моделирования зависимости коэффициента нефтеотдачи и вязкости нефти с шагом 10 и метрики модели

Fig. 3. Results of modeling the dependence of oil recovery factor and oil viscosity with step 10 and model metrics




Рис. 4. Результаты моделирования зависимости коэффициента нефтеотдачи и вязкости нефти с шагом 20 и метрики модели

Fig. 4. Results of modeling the dependence of oil recovery factor and oil viscosity with step 20 and model metrics




Рис. 5. Результаты моделирования зависимости коэффициента нефтеотдачи и содержания серы с шагом 1 и метрики модели

Fig. 5. Results of modeling the dependence of oil recovery factor and sulfur content with step 1 and model metrics




Рис. 6. Результаты моделирования зависимости коэффициента нефтеотдачи и содержания серы с шагом 10 и метрики модели

Fig. 6. Results of modeling the dependence of oil recovery factor and sulfur content with step 10 and model metrics




Рис. 7. Результаты моделирования зависимости коэффициента нефтеотдачи и содержания серы с шагом 20 и метрики модели

Fig. 7. Results of modeling the dependence of oil recovery factor and sulfur content with step 20 and model metrics




Рис. 8. Результаты моделирования зависимости коэффициента нефтеотдачи и плотностью нефти с шагом 1 и метрики модели

Fig. 8. Results of modeling the dependence of oil recovery factor and oil density with step 1 and model metrics




Рис. 9. Результаты моделирования зависимости коэффициента нефтеотдачи и плотностью нефти с шагом 10 и метрики модели

Fig. 9. Results of modeling the dependence of oil recovery factor and oil density with step 10 and model metrics




Рис. 10. Результаты моделирования зависимости коэффициента нефтеотдачи и плотностью нефти с шагом 20 и метрики модели

Fig. 10. Results of modeling the dependence of oil recovery factor and oil density with step 20 and model metrics

Для улучшения качества модели и избавления ее от переобучения были добавлены слои Dropout Layer. Результаты обучения показали, что модели с шагом 20 выдают наименьшие значения ошибок и в целом лучше приближены к исходным данным как на учебном, так и на тестовом наборе данных. Анализируя результаты моделирования, можно заключить, что на коэффициент нефтеотдачи в большей степени влияют вязкость нефти и содержание в ней серы.

Заключение

В проведенном исследовании показано влияние геологических характеристик на нефтеотдачу пласта с использованием нейронных сетей, а именно: архитектуры LSTM. Исходные данные являлись параметрами ряда нефтяных месторождений, включая вязкость нефти, содержание серы, плотность нефти и нефтеотдачу.

Анализ результатов исследования показал, что использование LSTM нейронных сетей позволяет эффективно моделировать влияние геологических характеристик на нефтеотдачу пласта. Обучение проводилось на протяжении 100 эпох, используя симоидальную функцию активации для LSTM нейронов. В итоге был организован слой с четырьмя блоками LSTM, а также выходной уровень, возвращающий одно значение.

Полученные результаты позволяют сделать вывод о том, что нейронные сети, основанные на архитектуре LSTM, могут быть эффективным инструментом для оценки влияния геологических характеристик на нефтеотдачу пласта. Дальнейшие исследования в этой области направлены на разработку более точных моделей прогнозирования нефтеотдачи, что имеет важное значение для нефтяной промышленности.

Список источников

1. Ибатуллин Р.Р., Ибрагимов Н.Г., Тахаутдинов Ш.Ф., Хисамов Р.С. Увеличение нефтеотдачи на поздней стадии разработки месторождений. Теория. Методы. Практика. М.: ООО «Недра-Бизнесцентр». 2004. 292 с.
2. Ленченкова Л.Е. Повышение нефтеотдачи пластов физико-химическими методами. М.: ООО «Недра-Бизнесцентр». 1998. 394 с.
3. Сургучев М.В. Вторичные и третичные методы увеличения нефтеотдачи пластов. М.: Недра. 1985. 308 с.
4. Желтов Ю.П. Разработка нефтяных месторождений. М.: Недра. 1986. 332 с.
5. Мандрик И.Э., Шахвердиев А.Х., Сулейманов И.В. Оценка и прогноз нефтеотдачи на основе моделирования нейронными сетями // Нефтяное хозяйство. 2005. №10. С. 36–39.
6. Муравьева Е.А., Коннов В.А. Оценка возможности применения искусственных нейронных сетей для прогнозирования добычи нефти // Информационные технологии. Проблемы и решения. 2020. № 3(12). С. 59–63.
7. Хасанов И.И., Хасанова З.Р., Шакиров Р.А., Недельченко О.И. Обзор применения нейросетей в области добычи и транспорта нефтепродуктов и углеводородного сырья. 2022. № 3–4. С. 11–15.
8. Евсюткин И.В., Марков Н.Г. Глубокие искусственные нейронные сети для прогнозирования значений дебита добывающих скважин // Изв. Томского политехнического университета. Инжиниринг георесурсов. 2020. Т. 331. № 11. С. 88–95.
9. Лебедева А.Ю., Скоров Д.С. Построение модели искусственной нейронной сети для выбора оптимального метода увеличения нефтеотдачи и разработка 3D модели для анализа вероятности применения методов воздействия на месторождении // В кн.: Новые идеи в науках о Земле. Материалы XIV Междунар. науч.-практ. конф.: в 7 томах. 2019. С. 449–451.
10. Гиматулинов Ш.К., Ширковский А.И. Физика нефтяного и газового пласта Изд. 4-е., стереотип. М.: Альянс. 2005. 311 с.
11. Демяненко Н.А., Пысенков В.Г., Лымарь И.В. и др. Физико-химические методы увеличения нефтеотдачи пластов // Нефтяное хозяйство. 2004. № 11. С. 22–23.
12. Джусулли А., Пал С. Библиотека Keras – инструмент глубокого обучения. Packt Publishing. 2017. 294 с.

Информация об авторе

Эльвира Нажмеддиновна Рамазанова – к.т.н., доцент кафедры математики и анализа данных;
доцент кафедры фундаментальных наук (ФН-1)
SPIN-код: не представлен
ORCID: <https://orcid.org/0000-0003-1802-8012>

Статья поступила в редакцию 03.06.2025
Одобрена после рецензирования 16.06.2025
Принята к публикации 30.06.2025

Original article

Assessing the influence of geological characteristics on oil recovery using neural networks

E.N. Ramazanova¹¹ Financial University under the Government of the Russian Federation (Moscow, Russia)¹ Bauman Moscow State Technical University (Moscow, Russia)¹ enramazanova@fa.ru

Abstract

Formulation of the problem. Geological characteristics of deposits have a significant impact on the selection and application of oil production technologies, and their correct assessment can help optimize these processes. The use of machine learning algorithms makes it possible to more accurately predict and analyze the relationship between geological parameters and the efficiency of production technologies, which in turn can lead to increased productivity and reduced costs. In this connection, the formulation of the problem within the framework of this article is the need to assess the influence of geological characteristics on oil recovery using machine learning methods.

Target – development of a neural network capable of analyzing geological data and predicting its impact on oil recovery.

Results. A database with the geological characteristics of oil fields was created and processed. A neural network was developed and trained based on the provided geological data to predict oil recovery. An analysis of the influence of individual geological characteristics on the productivity of an oil reservoir was carried out. The key factors influencing oil recovery of the reservoir have been identified and their significance has been assessed.

Practical significance. Possibility of improving reservoir oil recovery forecasting using neural networks. The development of such a model will make it possible to more effectively manage the oil production process, optimize work in the fields, as well as reduce operating costs and increase the efficiency of hydrocarbon production.

Keywords

Reservoir, viscosity, density, oil recovery, machine learning, neural networks

For citation

Ramazanova E.N. Assessing the influence of geological characteristics on oil recovery using neural networks. *Nonlinear World*. 2025. V. 23. № 3. P. 81–87. DOI: <https://doi.org/10.18127/j20700970-202503-10> (In Russian)

REFERENCES

1. Ibatullin R.R., Ibrarimov N.G., Tahautdinov Sh.F., Hisamov R.S. Uvelichenie nefteotdachi na pozdnej stadii razrabotki mestorozhdenij. *Teoriya. Metody. Praktika*. M.: OOO «Nedra-Biznescentr». 2004. 292 s. (In Russian).
2. Lenchenkova L.E. Povyshenie nefteotdachi plastov fiziko-himicheskimi metodami. M.: OOO «Nedra-Biznescentr». 1998. 394 s. (In Russian).
3. Surguchev M.V. Vtorichnye i tretichnye metody uvelicheniya nefteotdachi plastov. M.: Nedra. 1985. 308 s. (In Russian).
4. Zheltov Yu.P. Razrabotka neftyanyh mestorozhdenij. M.: Nedra. 1986. 332 s. (In Russian).
5. Mandrik I.E., Shahverdiev A.H., Sulejmanov I.V. Ocenka i prognoz nefteotdachi na osnove modelirovaniya nejronnymi setyami. *Neftyanoe hozyajstvo*. 2005. №10. S. 36–39 (In Russian).
6. Murav'eva E.A., Konnov V.A. Ocenka vozmozhnosti primeneniya iskusstvennyh nejronnyh setej dlya prognozirovaniya dobychi nefti. *Informacionnye tekhnologii. Problemy i resheniya*. 2020. № 3(12). S. 59–63 (In Russian).
7. Hasanov I.I., Hasanova Z.R., Shakirov R.A., Nedel'chenko O.I. Obzor primeneniya nejrosetej v oblasti dobychi i transporta nefteproduktov i uglevodorodnogo syr'ya. 2022. № 3–4. S. 11–15.
8. Evsyutkin I.V., Markov N.G. Glubokie iskusstvennye nejronnye seti dlya prognozirovaniya znachenij debita dobyvayushchih skvazhin. *Izv. Tomskogo politekhnicheskogo universiteta. Inzhiniring georesursov*. 2020. T. 331. № 11. S. 88–95 (In Russian).
9. Lebedeva A.Yu., Skorov D.S. Postroenie modeli iskusstvennoj nejronnoj seti dlya vybora optimal'nogo metoda uvelicheniya nefteotdachi i razrabotka 3D modeli dlya analiza veroyatnosti primeneniya metodov vozdejstviya na mestorozhdenii. V kn.: *Novye idei v naukah o Zemle. Materialy XIV Mezhdunar. nauch.-prakt. konf.: v 7 tomah*. 2019. S. 449–451 (In Russian).
10. Gimatudinov Sh.K., Shirkovskij A.I. *Fizika neftyanogo i gazovogo plasta* Izd. 4-e., stereotip. M.: Al'yans. 2005. 311 s. (In Russian).
11. Demyanenko N.A., Pysenkov V.G., Lyamar' I.V. i dr. *Fiziko-himicheskie metody uvelicheniya nefteotdachi plastov*. Neftyanoe hozyajstvo. 2004. № 11. S. 22–23 (In Russian).
12. Dzhulli A., Pal S. *Biblioteka Keras – instrument glubokogo obucheniya*. Packt Publishing. 2017. 294 c. (In Russian).

Information about the author

Elvira N. Ramazanova – Ph.D. (Eng.), Associate Professor of the Department of Mathematics and Data Analysis; Associate Professor of the Department of Fundamental Sciences (FN-1)

The article was submitted 03.06.2025

Approved after reviewing 16.06.2025

Accepted for publication 30.06.2025