

DOI: <https://doi.org/10.25689/NP.2024.3.123-136>

EDN LOBMLY

УДК 622.276.031:532.11

Расчёт пластового давления в добывающих скважинах при помощи методов машинного обучения

Гайсин А.А., Исроилов Н.К., Гилязов А.Х.

Институт «ТатНИПИнефть» ПАО «Татнефть» им. В.Д. Шашина,

Альметьевск, Россия

ГБОУ ВО «Альметьевский государственный технологический университет» -

«Высшая школа нефти», Альметьевск, Россия

Reservoir pressure calculation in producing wells using machine learning methods

A.A. Gaysin, N.K. Isroilov, A.Kh. Gilyazov

TatNIPIneft Institute – PJSC TATNEFT, Almetьевsk, Russia

Almetьевsk State University of Technology – Higher Petroleum School, Almetьевsk, Russia

E-mail: GaysinAA@tatneft.ru

Аннотация. Пластовое давление – один из важнейших факторов, определяющих энергетические возможности продуктивного пласта, производительность скважин и залежи в целом. Под пластовым понимают давление, при котором в продуктивном пласте нефть, газ, вода находятся в пустотах пластов-коллекторов. Производится постоянный мониторинг изменения пластового давления, и при его снижении применяются искусственные методы воздействия на залежь, в частности методы поддержания пластового давления. Темп снижения пластового давления, характеризующего энергетические ресурсы пласта, зависит от темпа отбора пластовой жидкости: нефти, воды и газа, который обусловлен проектом разработки месторождения, и от того, осуществляется или нет поддержание пластового давления.

В настоящей работе для прогнозирования пластового давления рассматривались методы машинного обучения. Особенностью работы является сравнительный анализ 11 методов машинного обучения для конкретного объекта разработки, а также выявление оптимального набора признаков для обучения моделей.

Применение данного метода в прогнозировании энергетического состояния эксплуатационных объектов позволит оперативно управлять разработкой месторождений, выстраивать эффективную систему ППД, планировать геолого-технические мероприятия, формировать программу исследований для уточнения пластового давления, проводить более точную настройку гидродинамических моделей на историю разработки.

Ключевые слова: машинное обучение, пластовое давление, забойное давление, алгоритмы, признаки

Для цитирования: Гайсин А.А., Исроилов Н.К., Гилязов А.Х. Расчёт пластового давления в добывающих скважинах при помощи методов машинного обучения // Нефтяная провинция.-2024.-№3(39).- С. 123-136. - DOI <https://doi.org/10.25689/NP.2024.3.123-136>. - EDN LOBMLY

Abstract. Reservoir pressure is a critical factor that determines energy potential of a producing reservoir and overall well and reservoir productivity. Reservoir pressure refers to the pressure of hydrocarbons (oil, gas, and water) contained within the reservoir voids. Changes in reservoir pressure should be continuously monitored. Once reservoir pressure decreases, methods for supplementing the natural reservoir energy are applied; particularly, reservoir pressure maintenance. Reservoir pressure decline rate depends on fluid (oil, water, and gas) production rates according to field development plan and implementation of reservoir pressure maintenance methods, if any. According to Operational Guidelines RD 153-39.0-109-01, downhole reservoir pressure measurements should be conducted every six months. However, some of these measurements may turn out to be unreliable, thus reducing the available reservoir energy state data. Moreover, direct measurements of reservoir pressure may require extended well shutdown periods to result in oil production losses and potential technical issues during well startup.

In this paper, machine learning methods for reservoir pressure prediction are considered. The present research effort is peculiar in that it presents comparative analysis of a variety of machine learning methods for specific production target, as well as reveals an optimal set of features for model training.

The results of the present research can be used to analyze the development status of hole sections in absence of reservoir pressure measurements, justify initial data adjustments for reservoir simulation modeling, and to prepare a list of wells for reservoir pressure studies aimed at objective evaluation of producing reservoir energy state while minimizing oil production losses.

Key words: machine learning, reservoir pressure, downhole pressure, algorithms, features

For citation: A.A. Gaysin, N.K. Isroilov, A.Kh. Gilyazov Raschot plastovogo davleniya v dobyvayushchikh skvazhinakh pri pomoshchi metodov mashinnogo obucheniya [Reservoir pressure calculation in producing wells using machine learning methods]. Neftyanaya Provintsiya, No. 3(39), 2024. pp. 123-136. DOI <https://doi.org/10.25689/NP.2024.3.123-136>. EDN LOBMLY (in Russian)

Машинное обучение широко используется в нефтегазовой отрасли, особенно при разработке месторождений с большим количеством сейсмических, петрофизических, геологических и технологических данных для решения задач заводнения, подбора геолого-технических мероприятий, построения и адаптации гидродинамических моделей и т.д. Основная идея машинного обучения заключается в создании алгоритмов и моделей, которые способны извлекать закономерности из данных и использовать их для прогнозирования, предсказания, классификации или принятия решений без явного программирования.

Основной принцип машинного обучения включает в себя использование данных для обучения модели и автоматического улучшения ее производительности на основе этих данных. Вместо того, чтобы разработчик явно написал инструкции или алгоритмы для решения конкретной задачи, модель обучается на данных, выявляет закономерности и создает предсказания или решения на основе этих закономерностей. Это позволяет моделям машинного обучения адаптироваться к новым данным и обучаться на основе опыта, что делает их полезными для решения широкого спектра задач, включая распознавание образов, прогнозирование трендов, медицинскую диагностику, рекомендательные системы, анализ текста и многое другое.

Главными методами машинного обучения являются обучение с учителем, обучение без учителя и обучение с подкреплением, в рамках которых модели учатся и развиваются, используя различные подходы к обработке и анализу данных.

1. Обучение с учителем:

– классификация: задача отнесения объектов к одной из категорий, например, определение литотипов пород по её признакам;

– регрессия: прогнозирование непрерывного значения на основе входных данных, например, подбор и предсказание дополнительной добычи нефти от проведения геолого-технических мероприятий.

2. Обучение без учителя:

- кластеризация: группировка объектов по их сходству, например, разделение скважин по координатам на участки;
- понижение размерности: уменьшение размерности данных с сохранением их структуры и важных характеристик.

3. Обучение с подкреплением:

- обучение агентов: создание агентов, способных выполнять определенные действия в среде с целью максимизации награды.

Каждая задача машинного обучения соответствует различным целям и методам решения, что позволяет моделям находить закономерности, создавать предсказания и принимать решения без необходимости явного программирования для каждой конкретной ситуации. Например, в работе [1] описан метод прогнозирования динамического пластового давления методами искусственного интеллекта. В основе метода лежат многомерный регрессионный анализ и нейронная сеть. Данный метод опробован на скважинах турнейско-фаменского, бобриковского и башкирского объектов разработки.

Новый алгоритм косвенного определения пластового давления с использованием методов Data Mining предложен в работе [2]. Алгоритм состоит из метода многокритериальной генетической оптимизации параметров системы частных решений обобщённого закона Дарси для радиального псевдоустановившегося трехфазного притока к наклонно направленной скважине.

В работе [3] предложен метод расчёта среднего пластового давления и коэффициента эффективности притока. Расчёт пластового давления производится по данным двух гидродинамических исследований (ГДИ), которые используются в разработанном математическом уравнении. После проверки фактических и расчётных показателей пластового давления получена хорошая сходимость.

В статье [4] описывается опыт применения аналитических методов определения пластового давления. Всего проанализировано три программных обеспечения (ПО). DSA является наиболее простым в использовании ПО, но существуют ограничения по априорным ГДИ. ПО «Панорама» позволяет охватить весь фонд скважин, а Toraze имеет наибольшие трудозатраты. Для каждого ПО сформированы области наиболее эффективного применения.

Разведочный анализ данных

Исследования выполнены для бобриковских отложений одного из самых крупных месторождений в России – Ромашкинского, находящегося в Республике Татарстан.

По исходному набору данных проведён разведочный анализ данных (Exploratory Data Analysis (EDA)) [5] – процесс исследования данных с целью выявления и понимания их основных характеристик, структуры и закономерностей, а также выявления потенциальных взаимосвязей между различными переменными. Основная цель EDA – получить представление о данных, выявить особенности и установить направление для более глубокого анализа.

Была поставлена задача определения пластового давления. С этой целью сформирована база данных геологических и технологических показателей за 24 года разработки бобриковских отложений Ромашкинского месторождения. В качестве входных использовались следующие параметры:

- дебит жидкости, приемистость воды, обводнённость;
- время добычи и закачки;
- забойное, пластовое давления;
- глубина спуска насоса;
- затрубное давление;
- абсолютная отметка.

По результатам EDA установлено, что наиболее влияющими признаками являются забойное давление, глубина спуска насоса и обводненность продукции (Рис. 1).

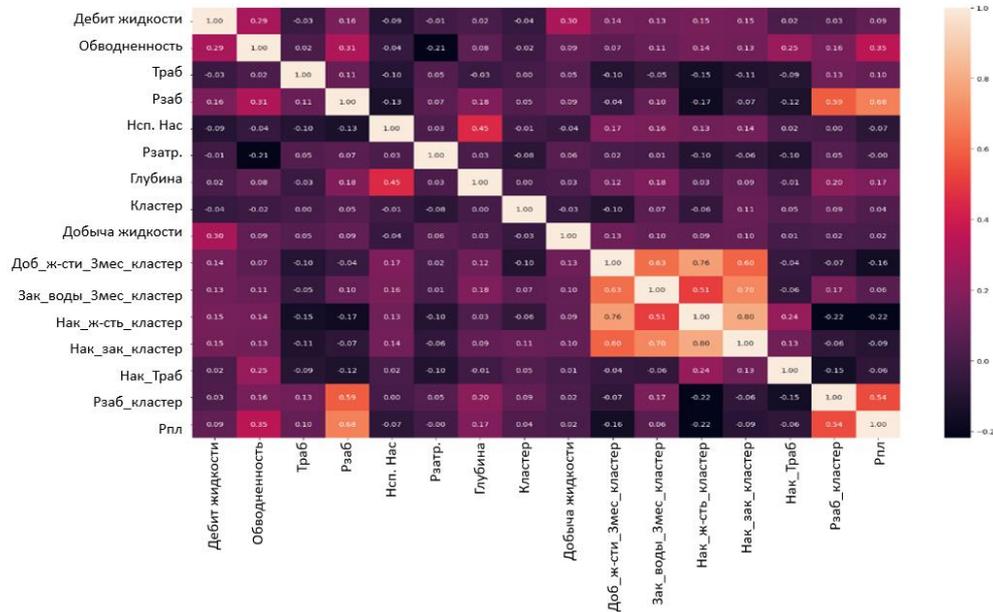


Рис. 1. Тепловая карта корреляции параметров

По распределению целевого параметра 80% значений пластового давления находится в интервале от 4 до 10 МПа, при этом отмечается наличие аномально низких и высоких исторических значений пластового давления для терригенных отложений бобриковского горизонта (Рис. 2).

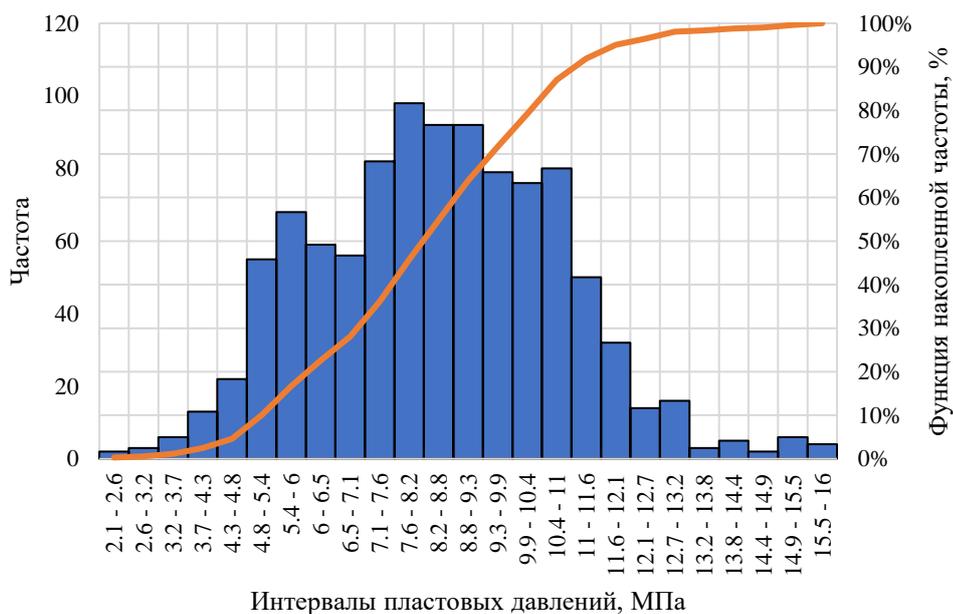


Рис. 2. Распределение целевого параметра $P_{пл}$

Обработка данных

В ходе оценки набора данных при помощи различных моделей машинного обучения рассчитана метрика R^2 и выбрана наилучшая.

В процессе производилась обработка данных, а именно:

- удаление строк с отсутствующими значениями;
- разделение скважин на кластеры с учётом влияния граничных скважин;
- удаление выбросов по $P_{заб}$;
- расчёт технологических показателей по каждому кластеру.

Следующим этапом производилась работа с подбором дополнительных признаков. Сначала была проведена кластеризация скважин по координатам методом гауссовой смеси. Модель гауссовой смеси – это статистическая модель, которая представляет собой смесь нескольких нормальных распределений (также известных как распределения Гаусса). Каждая нормальная компонента смеси имеет свою среднюю величину и дисперсию. Она широко применяется в области машинного обучения, обработки сигналов и статистики.

Для подбора количества кластеров использовался метод локтя, исходя из которого было выбрано оптимальное количество кластеров – 800. При этом также учитывалось количество скважин, входящих в один кластер. Визуализация кластеров скважин представлена на рис. 3. Далее по кластерам добавляются новые признаки: месячные и накопленные показатели по кластеру.

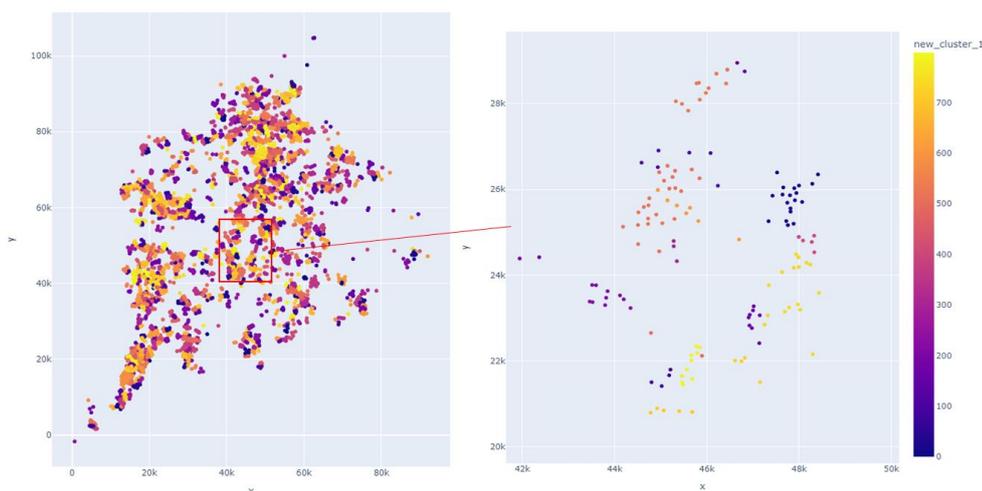


Рис. 3. Кластеры скважин

Удаление глобальных выбросов по забойному давлению производилось по значению первой производной $P_{\text{заб}}$ от времени. К глобальными выбросам относятся аномально высокие значения забойного давления, которые выделяются на всем интервале измерений. Для их выявления использовалась первая производная забойного давления по времени. Резкие изменения производной указывали на глобальные выбросы. Для выявления локальных выбросов применялся метод скользящего окна, который заключается в выборе некоторого окна (набор точек данных) и применении к нему некоторого статистического критерия, в частности z-score. Затем окно сдвигается на следующий набор точек данных, и процесс повторяется. Под локальными выбросами подразумевается аномально высокие значения забойного давления, которые выделяются только в пределах локального участка (окна) измерений.

После обработки набор данных был разделён на обучающую и тестовую выборки и проведена оценка различных моделей с применением кросс-валидации с разбиением данных на 15 частей. По результатам выводится среднее значение коэффициента детерминации и среднее абсолютное отклонение для каждой модели машинного обучения (Рис. 4). Выбрана наилучшая модель машинного обучения CatBoost с $R^2 = 0,691$.

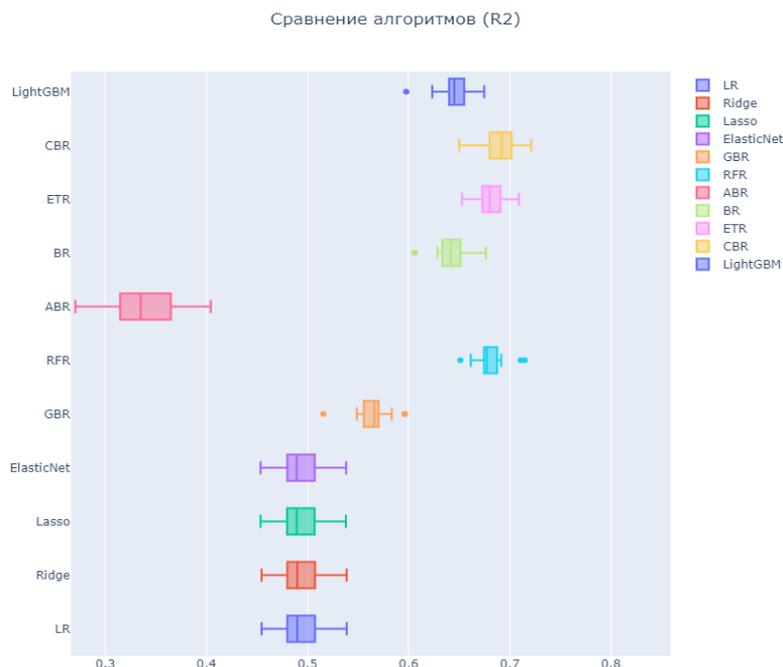


Рис. 4. Сравнение алгоритмов машинного обучения

Обучение и оптимизация модели машинного обучения

По результатам обучения модели рассчитана значимость признаков (Рис. 5), которая определяет, насколько сильно влияет признак на целевой параметр – пластовое давление. Так, по представленной на рис. 6 гистограмме отметим, что наиболее влияющими параметрами оказались забойное давление, глубина залегания пласта, номер кластера, фильтрационно-емкостные свойства, а также накопленные показатели по кластеру.

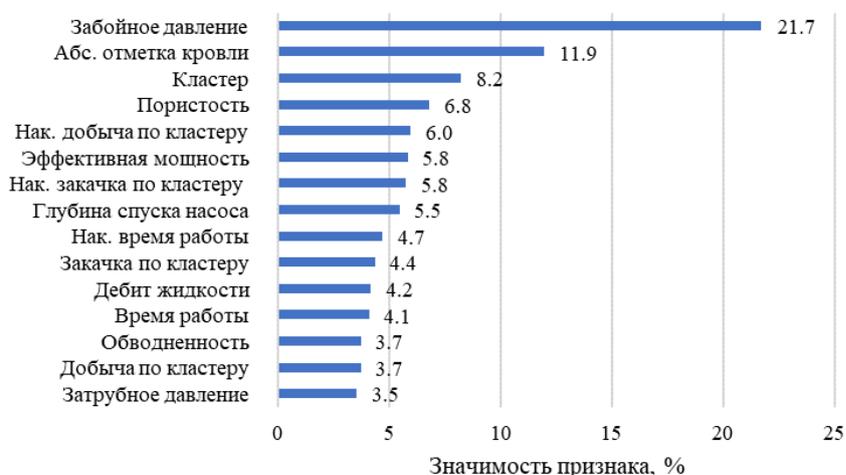


Рис. 5. Значимость признаков

CatBoost [6] – это библиотека градиентного бустинга, созданная Яндексом. Она использует небрежные деревья решений, чтобы вырастить сбалансированное дерево. Одни и те же функции используются для создания левых и правых разделений на каждом уровне дерева. По сравнению с классическими деревьями небрежные деревья более эффективны при реализации на процессоре и просты в обучении.

Для улучшения выбранного алгоритма CatBoost путем оптимизации ее гиперпараметров использовалась библиотека Optuna. После оптимизации полученные гиперпараметры использовались для обучения модели CatBoost (Рис. 6).

Hyperparameter Importance

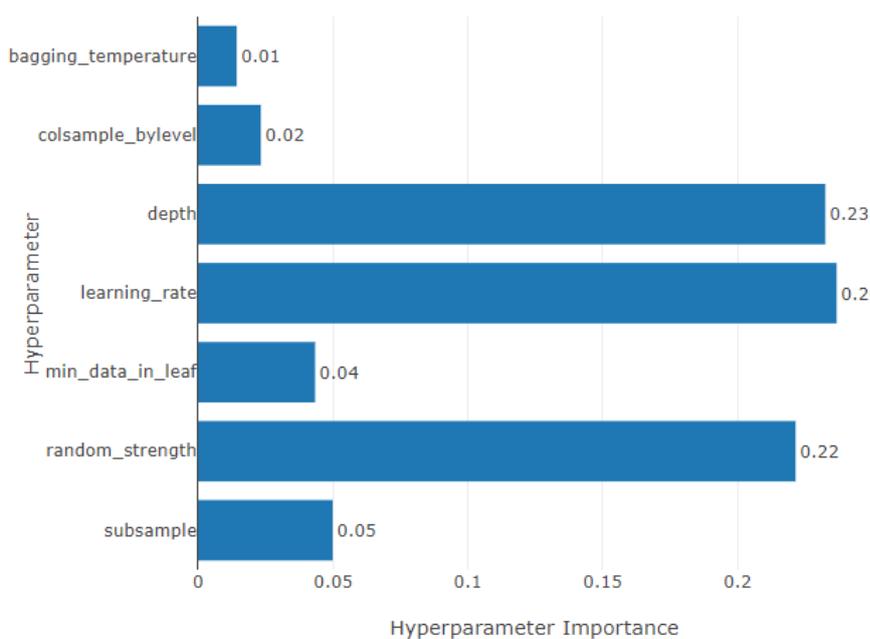


Рис. 6. Значимость признаков

После проведения оптимизации модели CatBoost результирующие метрики улучшились:

- MSE – 10.938 МПа;
- MAE – 0.727 МПа;
- R2 – 0.708 д.ед.

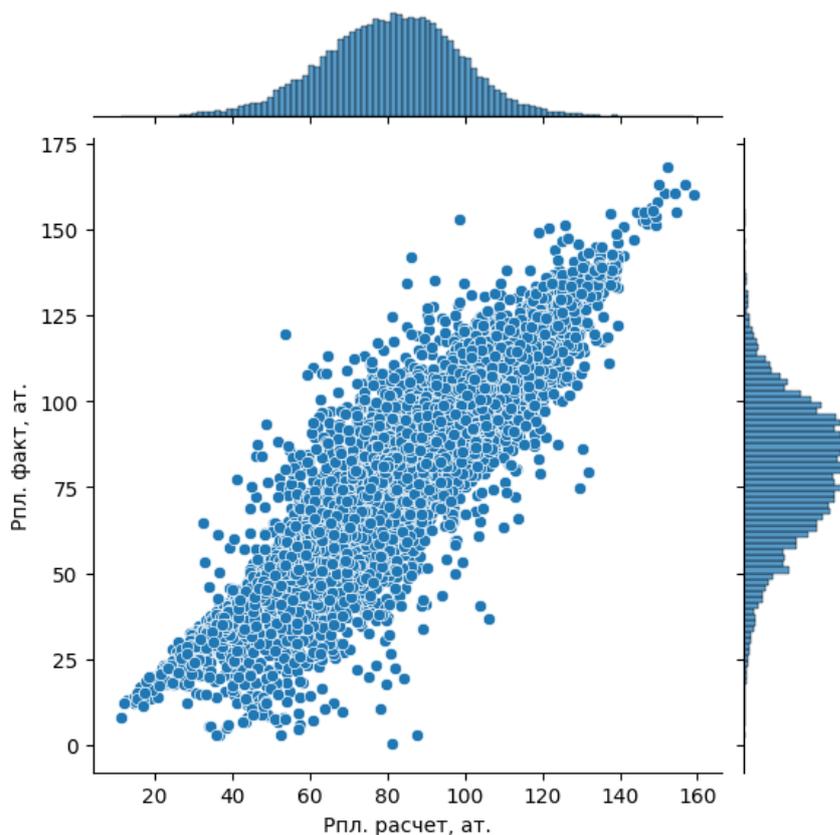


Рис. 7. Кросс-плот сравнения фактических и расчётных значений пластового давления

В результате произведён расчёт значений пластового давления. График по одной из скважин представлен на рис. 8.



Рис. 8. Сопоставление динамики фактического и расчётного пластового давлений по одной из скважин

По рис. 7–8 можно сделать вывод, что модель демонстрирует высокое качество определения пластового давления в скважинах, эксплуатирующих терригенные пласты бобриковского горизонта Ромашкинского месторождения. Колебания расчётного пластового давления связаны с тем, что моделирование пластового давления может включать в себя множество факторов, каждый из которых может быть оценен с некоторой степенью неточности, что приводит к колебаниям в расчетном давлении. А также в расчётах используются динамические параметры, такие как дебит жидкости, обводнённость, забойное давление, что также влияет на колебания расчётного пластового давления.

Заключение

Таким образом были проделаны первые шаги в разработки метода по расчёту пластового давления добывающих скважин при помощи алгоритмов машинного обучения. В ходе анализа была проведена обработка данных, включающая определение выбросов, нормализация, стандартизация, создание новых признаков. Обучение проводилось по нескольким моделям машинного обучения и выбрана модель, обладающая наилучшими метриками. Установлено, что на значение пластового давления больше всего влияют следующие признаки – забойное давление, абсолютная глубина, пористость, накопленная закачка по кластеру, эффективная толщина.

В перспективе планируется доработка метода путём добавления новых признаков, комбинирования различных методов машинного обучения, совершенствование используемого метода кластеризации, учёт метода измерения пластового давления.

Применение доработанного метода позволит увеличить объём данных по пластовому давлению, строить уточнённые карты изобар на любой временной период, повысить качество оперативно принимаемых решений при разработке нефтяных месторождений.

Список литературы

1. Захаров Л.А., Мартюшев Д.А., Пономарева И.Н. Прогнозирование динамического пластового давления методами искусственного интеллекта // Записки Горного института. – 2022. – Т. 253. – С. 23-32.
2. Харисов М.Н., Юнусова Э.А., Майский Р.А. Алгоритм косвенного определения пластового давления с использованием методов Data Mining // Проблемы сбора, подготовки и транспорта нефти и нефтепродуктов. – 2018. – № 3. – С. 40-48.
3. Hazim H. Al-Attar A Simple Method for Estimating Average Reservoir Pressure and Well Flow Efficiency in Volumetric Oil Reservoirs // Second ADRAC, Abu Dhabi 2014. – 10 p.
4. Опыт применения аналитических методов определения пластового давления / Е.А. Кузнецова [и др.] // Нефтепромысловое дело. – 2023. – № 6. – С. 12–16.
5. Secondary Analysis of Electronic Health Records: MIT Critical Data / Massachusetts Institute of Technology. – 435 p. – DOI 10.1007/978-3-319-43742-2.
6. Hancock J.T., Khoshgoftaar T.M. CatBoost for big data: an interdisciplinary review // Journal of Big Data. – 2020. – № 7. – 45 p.

References

1. Zakharov L.A., Martyushev D.A., Ponomareva I.N. *Prognozirovanie dinamicheskogo plastrovogo davleniya metodami iskusstvennogo intellekta* [Forecasting dynamic reservoir pressure by artificial intelligence methods]. *Zapiski Gornogo Instituta* [Journal of Mining Institute]. 2022, Vol. 253, pp. 23-32. (in Russian)
2. Kharisov M.N., Yunusova E.A., Maysky R.A. *Algoritm kosvennogo opredeleniya plastrovogo davleniya s ispolzovaniem metodov data mining* [Algorithm for indirect determination of reservoir pressure using data mining methods]. *Problemy Sбора, Podgotovki i Transporta Nefti i Nefteproduktov* [Problems of Gathering, Treatment and Transportation of Oil and Oil Products]. 2018, Vol. 3, pp. 40-48. (in Russian)
3. Hazim H. Al-Attar. A simple method for estimating average reservoir pressure and well flow efficiency in volumetric oil reservoirs. *Second ADRAC, Abu Dhabi, 2014*. 10 P. (in English)
4. Kuznetsova E.A., Nikulin S.E., Shilov A.V., Filatov M.A. *Opyt primeneniya analiticheskikh metodov opredeleniya plastrovogo davleniya* [The experience of using analytical methods for determining reservoir pressure]. *Neftepromyslovoe Delo* [Petroleum Engineering]. 2023, Vol. 6, pp. 12-16. (in Russian)
5. Secondary analysis of electronic health records – MIT critical data. *Massachusetts Institute of Technology*. 435 P. DOI 10.1007/978-3-319-43742-2. (in English)
6. Hancock, J.T., Khoshgoftaar, T.M. CatBoost for big data: an interdisciplinary review. *Journal of Big Data*, No.7, 2020, p. 45. (in English)

Сведения об авторах

Гайсин Альмир Айвазович, аспирант, кафедра разработки и эксплуатации нефтяных и газовых месторождений, ГБОУ ВО «Альметьевский государственный технологический университет» - «Высшая школа нефти», Институт «ТатНИПИнефть» ПАО «Татнефть» им. В.Д. Шашина

Россия, 423462, Альметьевск, ул. Ленина, 2

E-mail: GaysinAA@tatneft.ru

Исроилов Наврузбек Курбонович, аспирант, кафедра разработки и эксплуатации нефтяных и газовых месторождений, ГБОУ ВО «Альметьевский государственный технологический университет» - «Высшая школа нефти», Институт «ТатНИПИнефть» ПАО «Татнефть» им. В.Д. Шашина

Россия, 423462, Альметьевск, ул. Ленина, 2

E-mail: IsroilovNK@tatneft.ru

Гилязов Артур Халилович, аспирант, кафедра разработки и эксплуатации нефтяных и газовых месторождений, ГБОУ ВО «Альметьевский государственный технологический университет» - «Высшая школа нефти», Институт «ТатНИПИнефть» ПАО «Татнефть» им. В.Д. Шашина

Россия, 423462, Альметьевск, ул. Ленина, 2

E-mail: GilyazovAH@tatneft.ru

Authors

A.A. Gaysin, PhD Candidate, Chair of Oil and Gas Fields Development and Operation, Almeteyevsk State University of Technology – Higher Petroleum School, TatNIPIneft Institute – PJSC TATNEFT

2, Lenin Str., Almeteyevsk, 423462, Russian Federation

E-mail: GaysinAA@tatneft.ru

N.K. Isroilov, PhD Candidate, Chair of Oil and Gas Fields Development and Operation, Almeteyevsk State University of Technology – Higher Petroleum School, TatNIPIneft Institute – PJSC TATNEFT

2, Lenin Str., Almeteyevsk, 423462, Russian Federation

E-mail: IsroilovNK@tatneft.ru

A.Kh. Gilyazov, PhD Candidate, Chair of Oil and Gas Fields Development and Operation, Almeteyevsk State University of Technology – Higher Petroleum School, TatNIPIneft Institute – PJSC TATNEFT

2, Lenin Str., Almeteyevsk, 423462, Russian Federation

E-mail: GilyazovAH@tatneft.ru

Статья поступила в редакцию 03.06.2024

Принята к публикации 14.09.2024

Опубликована 30.09.2024