

Прогнозирование гидродинамических параметров состояния призабойной зоны скважин с помощью методов машинного обучения

А.В. Соромотин¹, Д.А. Мартюшев^{2*}, А.А. Мелехин²

¹ ООО «ЛУКОЙЛ-Инжиниринг» «ПермНИПИнефть» в г. Перми, Россия

² Пермский национальный исследовательский политехнический университет, Пермь, Россия

Актуальность разработки методики оперативной оценки призабойной зоны пласта (проницаемости призабойной зоны пласта и скин-фактора) обусловлена в первую очередь экономическими причинами, поскольку существующие подходы к ее определению, основанные на проведении гидродинамических исследований, ведут к недоборам нефти и повышению рисков необеспечения вывода скважины на режим. Современные методы работы с большими данными, например глубокое обучение искусственных нейронных сетей, позволяют осуществлять контроль за состоянием призабойной зоны пласта (ПЗП) скважин без их остановки на гидродинамические исследования, что сократит убытки у предприятий, осуществляющих добычу нефти, с одной стороны, и позволит проводить оперативный анализ для эффективного и своевременного применения технологий интенсификации, повышения нефтеотдачи пласта, с другой. В работе проанализированы существующие методы по определению призабойных характеристик пласта и подходов машинного обучения. Предложена методика для оперативной оценки состояния призабойной зоны пласта: проницаемости ПЗП и скин-фактора – с помощью обучения искусственных нейронных сетей на геологических и эксплуатационных данных и результатах интерпретации гидродинамических исследований на примере терригенных объектов нефтяных месторождений. Представлены результаты тестирования различных архитектур нейронных сетей для прогнозирования проницаемости ПЗП: количества слоев и нейронов в них с выбором наилучшей. Используются технические приемы для предотвращения переобучения моделей. Предложена авторская методика по оценке скин-фактора скважин с помощью комплексного анализа построенных статистических моделей и моделей обучения искусственных нейронных сетей для решения задачи регрессии.

Ключевые слова: терригенный коллектор, призабойная зона пласта, проницаемость, скин-фактор, машинное обучение, нейронная сеть

Для цитирования: Соромотин А.В., Мартюшев Д.А., Мелехин А.А. (2024). Прогнозирование гидродинамических параметров состояния призабойной зоны скважин с помощью методов машинного обучения. *Георесурсы*, 26(1), с. 109–117. <https://doi.org/10.18599/grs.2024.1.9>

1. Введение

Значительная часть оставшихся ресурсов нефтяных и газовых месторождений сосредоточена в коллекторах, характеризующихся сложным строением, проницаемостью и пористостью которых в основном являются низкими или сверхнизкими (Kantaatmadja et al., 2019; Alghazal et al., 2020; He et al., 2022), что вызывает дополнительные фильтрационные сопротивления при фильтрации углеводородов. Состояние призабойной зоны пласта (ПЗП) в коллекторах данного типа играет важную роль при движении флюидов из пласта в скважину. В настоящей работе рассмотрим такие параметры, как проницаемость ПЗП и скин-фактор, от которых зависят производительность добывающих и приемистость нагнетательных скважин, успешность методов интенсификации и методов повышения нефтеотдачи (Burne, Mcphee, 2012; Gouda, Attia, 2022).

В реальных условиях пласта ухудшение состояния призабойной зоны скважины может быть вызвано воздействием глинистого раствора при бурении продуктивного пласта, промывкой забоя различными технологическими жидкостями (водой, кислотой, паром и др.), кольматацией пустот пласта продуктами реакции, отложением органических веществ и др. (Al-Obaidi, 2016; Yang et al., 2023; Dvoynikov et al., 2024). На сегодняшний день известны различные подходы, которые позволяют оценивать и прогнозировать скин-фактор в различных геолого-физических условиях. Например, математическая модель скин-фактора, представленная в работе (Mahmoudi et al., 2016), учитывает повреждение пласта и конвергенцию потоков. В работе (Xie, 2015) выполнен анализ методом конечных элементов и изучено влияние длины щелевых отверстий и их структуры на фильтрацию потока флюидов, а также на скин-фактор. Авторы (Sivagnanam et al., 2017) в своей работе использовали CFD (Computational Fluid Dynamics) – k - ϵ -модель турбулентности, построенную на основе модифицированного закона Дарси, который учитывает инерционные эффекты. В исследованиях (Dong et al., 2018; Abobaker et al., 2021) предложены математические модели скин-фактора наклонных скважин

* Ответственный автор: Дмитрий Александрович Мартюшев
e-mail: martyushev@inbox.ru

© 2024 Коллектив авторов

Контент доступен под лицензией Creative Commons Attribution 4.0 License (<https://creativecommons.org/licenses/by/4.0/>)

в анизотропных коллекторах. Большинство моделей, основанных на оптимизации уравнения скин-фактора Хокинса, рассматривает радиус зоны повреждения в направлении от «носка» к «корню» ствола скважины как постоянное, линейное и параболическое распределение. В работе (Wang et al., 2023) оптимизировали модель скин-фактора, предположив, что распределение зоны повреждения вдоль ствола горизонтальной скважины имеет параболический убывающий вид. По мере увеличения содержания цемента порода может постепенно превращаться в хомогенную породу, что может ухудшить коллекторские свойства коллектора и постепенно превратить ее в непродуктивную породу, так как при этом в призабойной зоне скважины создается поверхностный слой (Al-Obaidi, Khalaf, 2018; Abdulaziz et al., 2022). В работе (Khairullin et al., 2016) рассмотрен подход, основанный на одновременном использовании данных об изменениях давления и температуры на забое скважины с последующей количественной оценкой параметров пласта и значения скин-фактора. Авторами (Kubota, Gioria, 2022; Goma et al., 2022) предложено оригинальное решение по использованию регрессионных моделей на основе ретроспективных значений забойного давления и добычи жидкости для оценки скин-фактора во время остановок скважин на исследовании. В указанных работах с применением различных подходов исследовано влияние геолого-технологических параметров на скин-фактор, определение которого имеет принципиальное значение для оценки успешности мероприятий интенсификации.

Прогнозирование проницаемости является одним из актуальных исследований в нефтяной и газовой промышленности (Zhou et al., 2024; Wang et al., 2024). На сегодняшний день имеется незначительное количество опубликованных работ по применению методов машинного обучения для решения проблемы неопределенности в прогнозировании проницаемости ПЗП (Bennis, Torres-Verdín, 2019; Eriavbe, Okene, 2019; Singh et al., 2020; Bennis, Torres-Verdín, 2023; Rashid et al., 2023; Pei et al., 2024). Наиболее адаптированным и часто применяемым методом из технологий искусственного интеллекта (ИИ) при прогнозировании свойств коллектора на основе данных геофизических исследований скважин являются нейронные сети и нечеткая логика (Dong et al., 2023). Эти методы оценивают и прогнозируют более точно и надежно параметры продуктивных пластов по сравнению с традиционными методами (Matinkia et al., 2023). Однако использование алгоритмов машинного обучения для интерпретации данных геофизических исследований с целью получения характеристик пласта осложняются проблемами субъективности интерпретации (Negara et al., 2016; Aygun et al., 2023; Liu et al., 2023). Искусственный интеллект используется для прогнозирования проницаемости по расчетному параметру HFU (Hydraulic Flow Units) (Bahaloo et al., 2023). Результаты показывают, что ИИ с HFU дает хорошую оценку проницаемости (Alobaidi, 2016). В исследовании (Nameed, Hamd-Allah, 2023) проницаемость, предсказанная с помощью модели ИИ, более точно описывала историю эксплуатации скважины. В (Liu et al., 2020; Zakharov et al., 2022) оценены возможность и точность автоматизированной интерпретации кривых восстановления давления для определения

призабойных характеристик пласта с помощью сверточной нейронной сети. Было также отмечено, что на расчеты проницаемости с помощью гидродинамических методов исследований сильно влияет неопределенность в интерпретации толщины пласта (Bist et al., 2023; Li et al., 2023).

Оценка и прогнозирование проницаемости призабойной зоны скважин и скин-фактора являются первостепенной задачей, решение которой позволит более обоснованно подходить к подбору технологического режима работы, методов интенсификации добычи скважин и повышения нефтеотдачи пласта. Однако в настоящее время этому уделяют незначительное внимание, для принятия различного рода решений используют проницаемость удаленной зоны пласта ($k_{узн}$), которую определяют по данным гидродинамических исследований скважин (ГДИС).

Целью настоящей статьи является совершенствование и адаптация методов машинного обучения, основанных на исторических данных разработки месторождений углеводородов, для оценки и прогнозирования таких параметров состояния призабойной зоны пласта, как скин-фактор и проницаемость ПЗП.

2. Материалы и методы

Использованы данные 486 гидродинамических исследований добывающих скважин (*реальные названия месторождений и расположения скважин не указаны в связи с конфиденциальностью данной информации*), обработанные в программном продукте KAPPA Workstation (модуль Saphir) с определением скин-фактора (S) и проницаемости УЗП ($k_{узн}$). Интерпретированы 39 индикаторных диаграмм с определением скин-фактора и проницаемости призабойной зоны пласта ($k_{пзп}$).

Для прогнозирования величин $k_{пзп}$ использованы следующие параметры:

- $P_{заб}$ – забойное давление, МПа;
- $P_{пл}$ – пластовое давление, МПа;
- $P_{н}$ – давление насыщения нефти газом, МПа;
- Q – дебит жидкости, м³/сут;
- h – эффективная толщина пласта, м;
- $\Gamma_{ф}$ – газовый фактор, м³/т;
- W – обводненность, %;
- m – пористость, %;

$$R_k = \frac{Q}{(P_{пл} - P_{заб}) \cdot h} \cdot \frac{m^2}{\text{сут} \cdot \text{МПа}}, \text{ – расчетный коэффициент}$$

удельной продуктивности скважины для повышения точности модели;

S – скин-фактор.

Для установления индивидуальных закономерностей формирования проницаемости призабойной зоны пласта (фазовой по нефти) использовалась выборка, предварительно ранжированная по проницаемости $k_{пзп}$ от максимальных до минимальных значений. После ранжирования выполнялась процедура пошагового моделирования с помощью множественной линейной регрессии. Данный процесс подробно описан в работах (Galkin et al., 2021; Popomareva et al., 2022), поэтому в настоящей статье обозначены только его основные этапы. На первом этапе строится модель с использованием первых трех строк таблицы с выборкой данных ($n = 3$), далее вторая модель с выборкой данных ($n = 4$) и т.д.

Из рис. 1 видно, что резкое снижение коэффициента множественной корреляции (R^2) происходит при проницаемости ПЗП менее 1 мкм². Несмотря на относительно большое значение R^2 на полном наборе данных (0,812), модель обладает большой стандартной ошибкой среднего – 0,191 мкм².

Модели, построенные для различных диапазонов проницаемости ПЗП, представлены на рис. 2 и в табл. 1. Для каждой модели также рассчитаны статистические характеристики работоспособности. Согласно анализу коэффициентов детерминации происходит снижение точности моделей и влияния признаков с уменьшением диапазона проницаемости.

Следующим этапом является прогнозирование $k_{\text{пзп}}$ на основе обучения полносвязной нейронной сети с различными конфигурациями слоев. В качестве дополнительных признаков для обучения полносвязной нейронной сети добавлены дополнительные расчетные параметры:

$P_{\text{заб}}/P_{\text{пл}}$ – отношение забойного давления к пластовому;
 $P_{\text{заб}}/P_{\text{нас}}$ – отношение забойного давления к давлению насыщения.

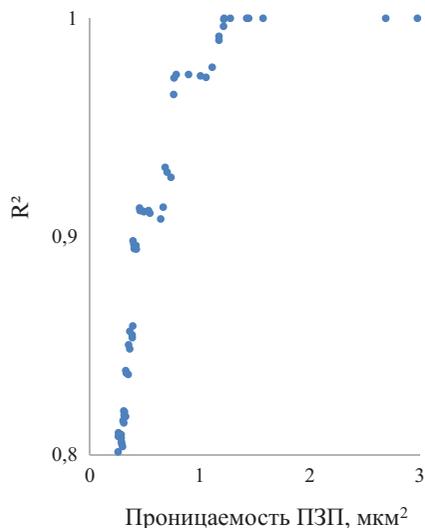


Рис. 1. Коэффициент множественной корреляции (R^2) на разных диапазонах проницаемости ПЗП

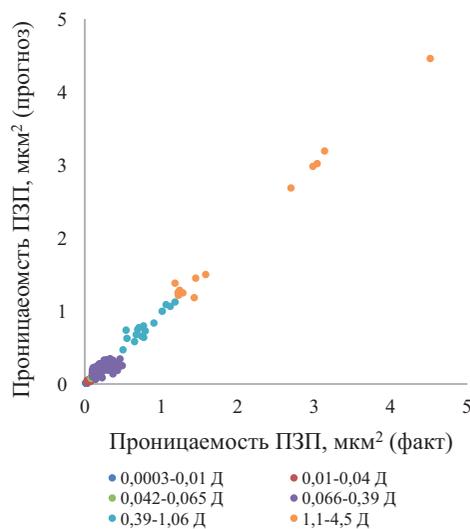


Рис. 2. Диаграмма рассеяния прогнозных и фактических значений проницаемости ПЗП (ранжирование по проницаемости ПЗП)

Для реализации алгоритмов использовалась открытая библиотека Keras, написанная на языке Python и обеспечивающая взаимодействие с искусственными нейронными сетями (<https://keras.io/>). В модели обучения заложена ее остановка на ранних эпохах (итерациях), когда ошибка на валидационном наборе данных перестает улучшаться или начинает ухудшаться для предотвращения переобучения и оптимизации ее обобщающей способности. Эта техника реализуется путем периодического вычисления ошибки на валидационном наборе данных после каждой эпохи обучения. Если ошибка перестала уменьшаться или начала расти в течение заданного количества эпох, обучение модели останавливается и возвращается лучшая модель, полученная до этого момента. Функция активации ReLu на выходном слое есть линейная функция активации.

Нами протестированы архитектуры с различным количеством слоев (от 1 до 4) и количеством нейронов (50, 100, 150, 200). Выбрана наилучшая модель с 4 слоями по 100 нейронов в каждом. Архитектура модели и набор исходных данных для прогнозирования проницаемости ПЗП представлены на рис. 3.

| Диапазон проницаемости ПЗП, мкм ² | Регрессионная модель |
|--|--|
| 1,1–4,5 | $k = -21,813 - 0,017R + 0,017W + 0,137S + 0,03Q + 0,418h - 3,243P + 1,976P_{\text{пл}} + 3,179P_{\text{нас}} + 0,041m + 0,034\Gamma_{\text{ф}}$ $R^2: 0,429; 0,767; 0,961; 0,971; 0,986; 0,989; 0,989; 0,995; 0,998; 0,999$ |
| 0,39–1,06 | $k = 0,777 - 0,014R + 0,0002W + 0,019\Gamma_{\text{ф}} + 0,194P - 0,748P_{\text{пл}} + 0,721P_{\text{нас}} + 0,019S + 0,017Q + 0,07h + 0,003m$ $R^2: 0,268; 0,372; 0,377; 0,417; 0,435; 0,519; 0,697; 0,702; 0,795; 0,797$ |
| 0,066–0,39 | $k = 0,556 + 0,014R + 0,001W + 0,022P - 0,007m + 0,001Q + 0,003h - 0,009P_{\text{пл}} + 0,009P_{\text{нас}} + 0,001S$ $R^2: 0,365; 0,436; 0,441; 0,457; 0,469; 0,475; 0,488; 0,504; 0,507$ |
| 0,042–0,065 | $k = -0,119 + 0,011P_{\text{пл}} + 0,001m + 0,001P_{\text{нас}} + 0,004R - 0,001h - 0,0002S$ $R^2: 0,149; 0,212; 0,273; 0,372; 0,471; 0,498$ |
| 0,01–0,04 | $k = 0,016 + 0,013R + 0,0001W + 0,001P_{\text{пл}} - 0,0003h - 0,0004S$ $R^2: 0,204; 0,390; 0,475; 0,510; 0,532$ |
| 0,0003–0,01 | $k = -0,002 + 0,018R + 0,0002P_{\text{пл}} + 0,00002W$ $R^2: 0,569; 0,665; 0,697$ |

Табл. 1. Многомерные регрессионные модели для разных диапазонов проницаемости ПЗП. Примечание: $P_{\text{заб}}$ – забойное давление, МПа; $P_{\text{пл}}$ – давление пластовое, МПа; $P_{\text{нас}}$ – давление насыщения, МПа; Q – дебит жидкости, м³/сут; h – эффективная толщина пласта, м; $\Gamma_{\text{ф}}$ – газовый фактор, м³/т; W – обводненность, %; m – пористость, %; R_k – удельная продуктивность скважины; S – скин-фактор.

Для прогнозирования скин-фактора S в исходную базу данных добавлены дополнительные расчетные параметры:

- $\kappa_{пзп}^T$ – медианное значение проницаемости ПЗП всех исторических данных интерпретации по скважине;
- $\kappa_{узп}^T$ – медианное значение проницаемости УЗП всех исторических данных интерпретации по скважине;
- $\kappa_{пзп}^T / \kappa_{узп}^T$ – отношение медианного значения ПЗП к медианному значению УЗП.
- $\kappa_{пзп}^{cp}$ – среднее значение проницаемости ПЗП всех исторических данных интерпретации по скважине;
- $\kappa_{узп}^{cp}$ – среднее значение проницаемости УЗП всех исторических данных интерпретации по скважине;
- $\kappa_{пзп}^{cp} / \kappa_{узп}^{cp}$ – отношение среднего значения ПЗП к среднему значению УЗП.

Предлагаемая методика по оценке S заключается в предварительном прогнозировании проницаемости ПЗП (рис. 3) с последующей корректировкой медианного значения проницаемости ПЗП скважины и, как следствие, отношения медианных значений проницаемостей ПЗП и УЗП в качестве одного из основных исходных параметров для модели нейронной сети прогнозирования скин-фактора (рис. 4).

Протестированы архитектуры с различным количеством слоев (от 1 до 4) и нейронов (50, 100, 150, 200).

Выбрана наилучшая модель с 4 слоями по 100 нейронов в каждом, как и для проницаемости ПЗП. В качестве дополнительной меры предотвращения переобучения добавлены Dropout-слои. Эта техника случайным образом отключает нейроны в слоях и способствует улучшению обобщающей способности. Архитектура модели и набор исходных данных для прогнозирования скин-фактора представлены на рис. 4.

На рис. 5 и 6 представлены диаграммы рассеяния скин-фактора и отношения проницаемостей; скин-фактора и отношения медианных значений проницаемости УЗП/ПЗП за весь срок эксплуатации по каждой скважине. При использовании медианных значений коэффициент R^2 уменьшался с 0,834 до 0,425.

3. Результаты

Для прогнозирования проницаемости ПЗП использовалась полносвязная нейронная сеть. На рис. 7 и 8 представлены диаграммы рассеяния тренировочной и тестовой выборок. Средняя абсолютная ошибка на тестовой выборке составляет 0,024 мкм² при $R^2 = 0,986$.

На следующем этапе строилась зависимость функции потерь от количества эпох для модели скин-фактора, представленная на рис. 9.

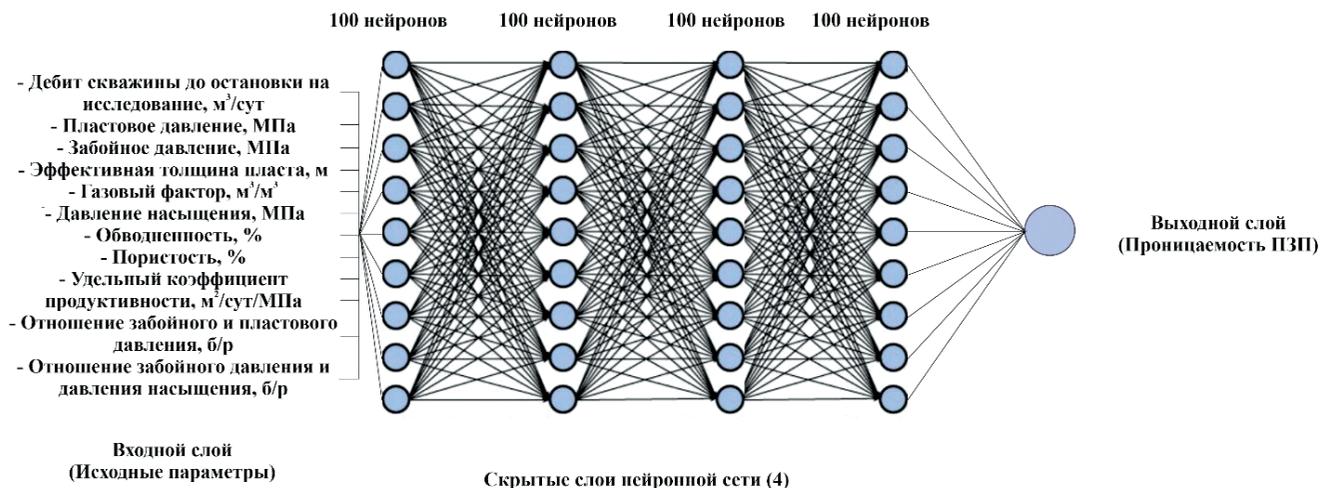


Рис. 3. Архитектура полносвязной нейронной сети для прогнозирования проницаемости призабойной зоны пласта

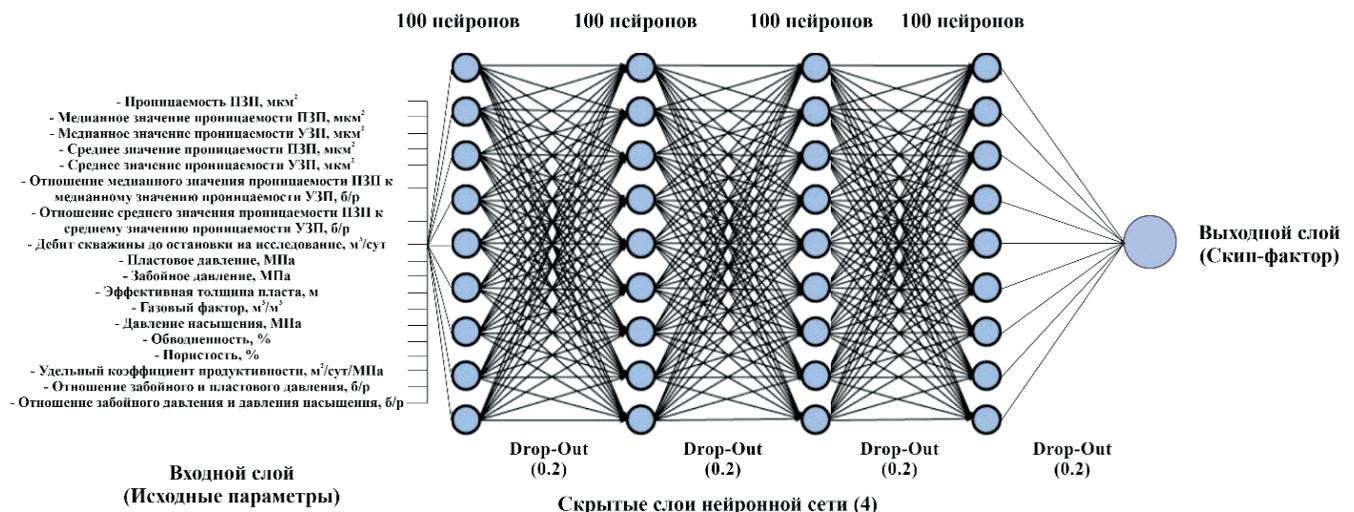


Рис. 4. Архитектура полносвязной нейронной сети для прогнозирования скин-фактора

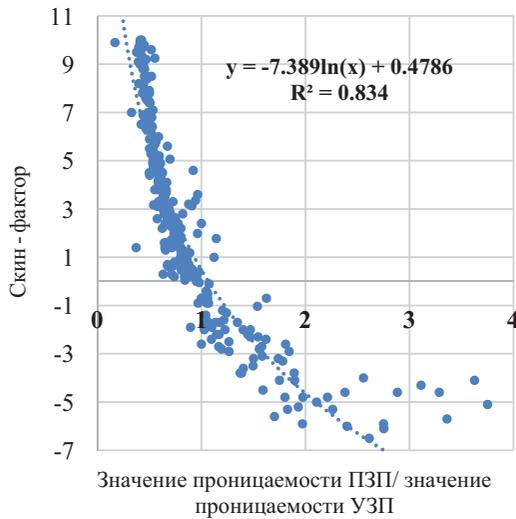


Рис. 5. Диаграмма рассеяния скин-фактора от отношения проницаемости ПЗП к УЗП

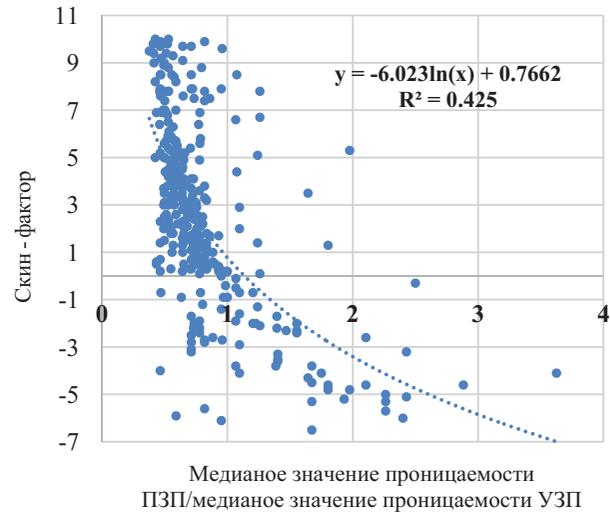


Рис. 6. Диаграмма рассеяния скин-фактора от отношения медианных значений проницаемости ПЗП к УЗП

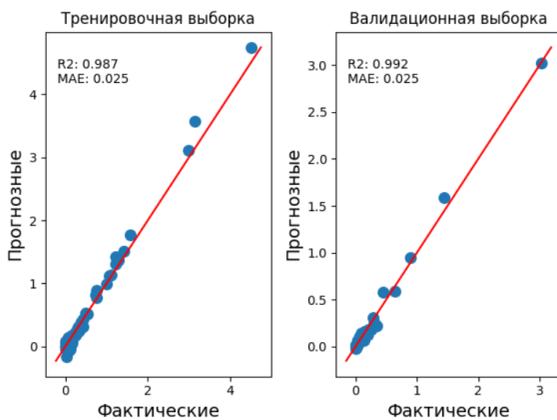


Рис. 7. Диаграммы рассеяния проницаемости ПЗП на тренировочной и валидационной выборках

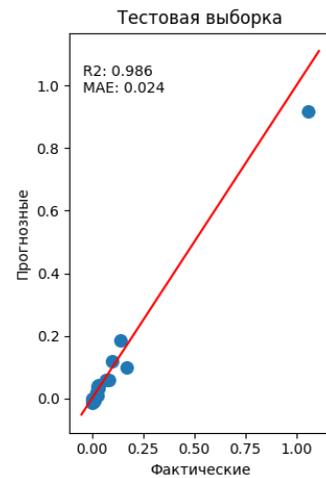


Рис. 8. Диаграмма рассеяния проницаемости ПЗП на тестовой выборке

Из рис. 9 видно, что модель нейронной сети по прогнозированию скин-фактора поддается обучению, переобучение отсутствует. Средняя абсолютная ошибка на тестовой выборке составляет 1,8 ($R^2 = 0,644$). Эпохой нейронной сети считается проход полным набором данных через нейронную сеть. Во время каждой эпохи система получает входные данные, пропускает через слои, вычисляет ошибку и корректирует веса с помощью алгоритма обратного распространения ошибки. Функция потерь нейронной сети используется для измерения разницы между предсказанными и фактическими значениями. Цель функции потерь заключается в минимизации ошибки. В нашем случае применена среднеквадратичная ошибка в качестве функции потерь. Для прогнозирования скин-фактора использована полносвязная нейронная сеть. На рис. 10 и 11 представлены диаграммы рассеяния на тренировочной и валидационной выборках.

Рассмотренные подходы и методы являются первым этапом создания комплексной системы по оценке состояния призабойной зоны пласта на основе значительных промышленных данных (Big Data), полученных в процессе разработки нефтегазовых объектов.

Результаты полученных исследований свидетельствуют о хорошей прогностической способности проницаемости ПЗП на основе продуктивности скважин. Получены более высокие оценки точности прогнозирования с помощью полносвязной искусственной нейронной сети, чем с помощью модели множественной линейной регрессии. Средняя абсолютная ошибка на тестовой выборке составляет 0,024 мкм², для множественной линейной регрессии она равна 0,190 мкм². Коэффициент детерминации R^2 прогнозных и фактических значений проницаемости ПЗП на тестовой выборке составляет 0,986.

Предложена методика по оценке скин-фактора скважины. Отметим, что точность определения скин-фактора по этой методике зависит от неопределенности проницаемости УЗП, качества данных гидродинамических исследований и их интерпретации. Модель нейронной сети по прогнозированию скин-фактора поддается обучению, переобучение отсутствует. Средняя абсолютная ошибка на тестовой выборке составляет 1,8. Коэффициент детерминации R^2 прогнозных и фактических значений скин-фактора составляет 0,644, для множественной линейной регрессии он равен 0,427.

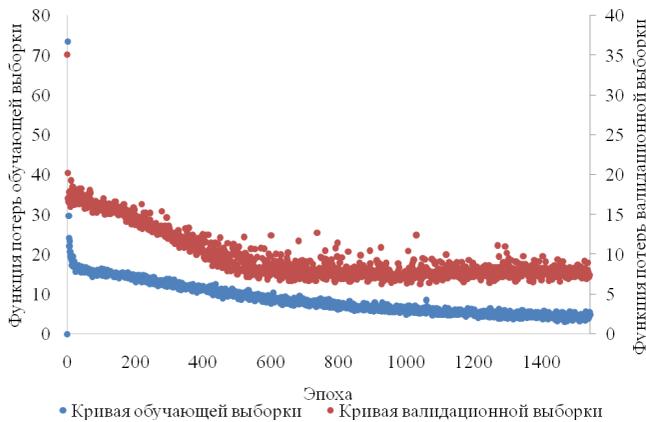


Рис. 9. Кривые обучения тренировочной и валидационной выборок модели скин-фактора

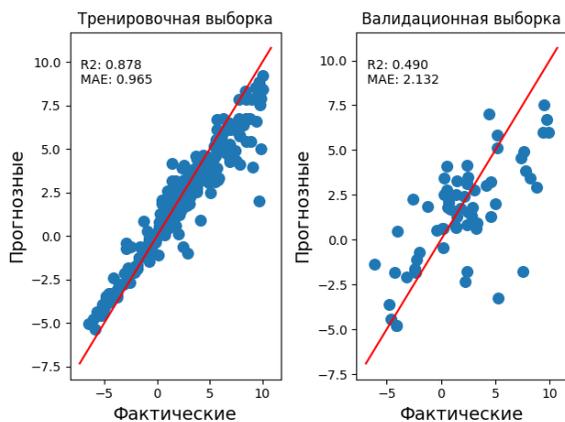


Рис. 10. Диаграммы рассеяния скин-фактора на тренировочной и валидационной выборках

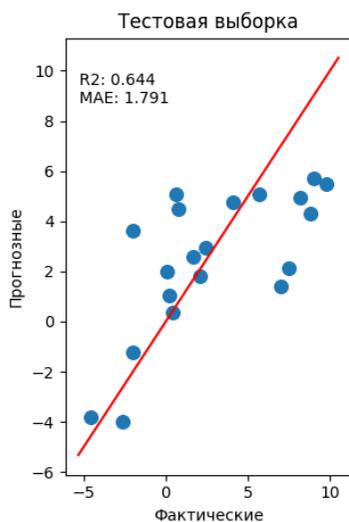


Рис. 11. Диаграмма рассеяния скин-фактора на тестовой выборке

4. Заключение

В работе предложена методика оперативной оценки состояния ПЗП на основе исторических данных разработки объекта: геологической и эксплуатационной информации, а также результатов интерпретации гидродинамических исследований. По этим данным построены следующие модели искусственных нейронных сетей для прогнозирования параметров призабойной зоны пласта:

1) модель прогнозирования проницаемости ПЗП на основе обучения нейронной сети: средняя абсолютная ошибка на тестовой выборке составляет 0,024 мкм², для множественной линейной регрессии она равна 0,190 мкм²; коэффициент детерминации R^2 прогнозных и фактических значений проницаемости ПЗП на тестовой выборке составляет 0,986.

2) модель прогнозирования скин-фактора на основе обучения нейронной сети: средняя абсолютная ошибка на тестовой выборке составляет 1,8; коэффициент детерминации R^2 прогнозных и фактических значений скин-фактора составляет 0,644, для множественной линейной регрессии она равна 0,427.

Проницаемость ПЗП достаточно точно определяется на основе характеристик продуктивности скважин. Подход, предложенный в работе, по определению скин-фактора осложнен точностью интерпретации ГДИС. В будущих исследованиях планируется использование рекуррентных и сверточных нейронных сетей для исследования динамических составляющих формирования призабойной зоны пласта и создания комплексного подхода для решения поставленной задачи.

Финансирование

Работа выполнена при поддержке Министерства науки и высшего образования Российской Федерации (проект № FSNM-2024-0005).

Литература

- Abdulaziz A.M., Ali M.K., Hafad O.F. (2022). Influences of Well Test Techniques and Uncertainty in Petrophysics on Well Test Results. *Energies*, 15(19), 7414. <https://doi.org/10.3390/en15197414>
- Abobaker E., Elsanouse A., Khan F., Rahman M.A., Aborig A., Noah K. (2021). A New Evaluation of Skin Factor in Inclined Wells with Anisotropic Permeability. *Energies*, 14(17), 5585. <https://doi.org/10.3390/en14175585>
- Alghazal M., Alshakhs M., Bouaouaja M. (2020). Technology integration to assess end-point oil saturation of the relative permeability curves. *International Petroleum Technology Conference*. Dhahran, Kingdom of Saudi Arabia. <https://doi.org/10.2523/iptc-19614-ms>
- Alobaidi D.A. (2016). Permeability prediction in one of iraqi carbonate reservoir using hydraulic flow units and neural networks. *Iraqi Journal of Chemical and Petroleum Engineering*, 17(1), pp. 1–11. <https://doi.org/10.31699/IJCP.2016.1.1>
- Al-Obaidi S.H. (2016). Improve The Efficiency Of The Study Of Complex Reservoirs And Hydrocarbon Deposits-East Baghdad Field. *International Journal of Scientific & Technology Research*, 5(8), pp. 129–131.
- Al-Obaidi S.H., Khalaf F.H. (2018). The Effects Of Hydro Confining Pressure On The Flow Properties Of Sandstone And Carbonate Rocks. *Journal of Geology & Geophysics*, 7(2), 327. <https://doi.org/10.4172/2381-8719.1000327>
- Aygun A., Maulik R., Karakus A. (2023). Physics-informed neural networks for mesh deformation with exact boundary enforcement. *Engineering Applications of Artificial Intelligence*, 125, 106660. <https://doi.org/10.1016/j.engappai.2023.106660>
- Bahaloo S., Mehrizadeh M., Najafi-Marghmaleki A. (2023). Review of application of artificial intelligence techniques in petroleum operations. *Petroleum Research*, 8(2), pp. 167–182. <https://doi.org/10.1016/j.ptlrs.2022.07.002>
- Bennis M., Torres-Verdin C. (2019). Estimation of Dynamic Petrophysical Properties from Multiple Well Logs Using Machine Learning and Unsupervised Rock Classification. *SPWLA 60th Annual Logging Symposium*. The Woodlands, Texas, USA, SPWLA-2019-KKKK. https://doi.org/10.30632/T60ALS-2019_KKKK
- Bennis M., Torres-Verdin C. (2023). Automatic Multiwell Assessment of Flow-Related Petrophysical Properties of Tight Gas Sandstones Based on The Physics of Mud-Filtrate Invasion. *SPE Reservoir Evaluation and Engineering*, 26(3), pp. 543–564. <https://doi.org/10.2118/214668-PA>

- Bist N., Nair A., Yadav K., Sircar A. (2023). Diverting agents in the oil and gas industry: A comprehensive analysis of their origins, types, and applications. *Petroleum Research*. <https://doi.org/10.1016/j.ptlrs.2023.09.004>
- Dong S.-Q., Zhong Z.-H., Cui X.-H., Zeng L.-B., Yang X., Liu J.-J., Sun Y.-M., Hao J.-R. (2023). A deep kernel method for lithofacies identification using conventional well log. *Petroleum Science*, 20(3), pp. 1411–1428. <https://doi.org/10.1016/j.petsci.2022.11.027>
- Dong W., Wang X., Wang J. (2018). A new skin factor model for partially penetrated directionally-drilled wells in anisotropic reservoirs. *Journal of Petroleum Science and Engineering*, 161, pp. 334–348. <https://doi.org/10.1016/j.petrol.2017.11.062>
- Dvoynikov M.V., Minaev Ya.D., Minibaev V.V., Kambulov E.Yu., Lamosov M.E. (2024). Technology for killing gas wells at managed pressure. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 335(1), pp. 7–18. <https://doi.org/10.18799/24131830/2024/1/4315>
- Eriaybe F.E., Okene U.O. (2019). Machine Learning Application to Permeability Prediction Using Log & Core Measurements: A Realistic Workflow Application for Reservoir Characterization. *SPE Nigeria Annual International Conference and Exhibition*, Lagos, Nigeria, SPE-198874-MS. <https://doi.org/10.2118/198874-MS>
- Galkin V.I., Martyushev D.A., Ponomareva I.N., Chernykh I.A. (2021). Developing features of the near-bottomhole zones in productive formations at fields with high gas saturation of formation oil. *Journal of Mining Institute*, 249, pp. 386–392. <https://doi.org/10.31897/PMI.2021.3.7>
- Gomaa S., Emara R., Mahmoud O., El-hoshoudy A.N. (2022). New correlations to calculate vertical sweep efficiency in oil reservoirs using nonlinear multiple regression and artificial neural network. *Journal of King Saud University – Engineering Sciences*, 34(7), 368–375. <https://doi.org/10.1016/j.jksues.2021.07.010>
- Gouda A., Attia A.M. (2022). Development of a new approach using an artificial neural network for estimating oil formation volume factor at bubble point pressure of Egyptian crude oil. *Journal of King Saud University – Engineering Sciences*, 36(1), pp. 72–80. <https://doi.org/10.1016/j.jksues.2022.08.001>
- Hameed M.R.A., Hamd-Allah S.M. (2023). Studying the Effect of Permeability Prediction on Reservoir History Matching by Using Artificial Intelligence and Flow Zone Indicator Methods. *Iraqi Geological Journal*, 56(1E), pp. 9–21. <https://doi.org/10.46717/igj.56.1E.2ms-2023-5-12>
- He Y., Liu Y., Cai H. (2022). Fine characterisation of remaining oil using timevarying numerical simulation: Experimental study. Characterisation in Model, and Application in QHD Oilfield. *Offshore Technology Conference Asia*. Virtual and Kuala Lumpur, Malaysia, OTC-31410-MS. <https://doi.org/10.4043/31410-ms>
- Kantaatmadja B.P., Jiang L., Ralphy B. (2019). Hydrocarbon identification and evaluation in a bioturbated reservoir with new-generation pulsed neutron technology. *SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition*. Bali, Indonesia, SPE-196364-MS. <https://doi.org/10.2118/196364-ms>
- Khairullin M.K., Shamsiev, M.N., Gadilshina, B.R., Morozov, P. E., Abdullin, A. I., Badertdinova, E.R. (2016). Determination of the Parameters of the Hole Bottom Zone of a Vertical Well from the Results of Thermodynamic Investigations. *Journal of Engineering Physics and Thermophysics*, 89(6), pp. 1449–1453. <https://doi.org/10.1007/s10891-016-1512-7>
- Kubota L., Gioria R.S. (2022). Data-driven technique estimates skin factor and average pressure during oil-flowing periods. *Journal of Petroleum Science and Engineering*, 219, 111061. <https://doi.org/10.1016/j.petrol.2022.111061>
- Li D., Zhou X., Xu Y., Wan Y., Zha W. (2023). Deep learning-based analysis of the main controlling factors of different gas-fields recovery rate. *Energy*, 285, 128767. <https://doi.org/10.1016/j.energy.2023.128767>
- Liu S., Fan M., Lu D. (2023). Uncertainty quantification of the convolutional neural networks on permeability estimation from micro-CT scanned sandstone and carbonate rock image. *Geoenergy Science and Engineering*, 230, 212160. <https://doi.org/10.1016/j.geoen.2023.212160>
- Liu X., Li D., Yang J., Zha W., Zhou Z., Gao L., Han J. (2020). Automatic well test interpretation based on convolutional neural network for infinite reservoir. *Journal of Petroleum Science and Engineering*, 195, 107618. <https://doi.org/10.1016/j.petrol.2020.107618>
- Mahmoudi M., Fattahpour V., Nouri A., Yao T., Baudet B.A., Leitch M., Fermianiuk B. (2016). New Criteria for Slotted Liner Design for Heavy Oil Thermal Production. *SPE Thermal Well Integrity and Design Symposium*, Banff, Alberta, Canada, SPE-182511-MS. <https://doi.org/10.2118/182511-MS>
- Matinkia M., Hashami R., Mehrad M., Hajsaeedi M. R., Velayati A. (2023). Prediction of permeability from well logs using a new hybrid machine learning algorithm. *Petroleum*, 9(1), pp. 108–123. <https://doi.org/10.1016/j.petlm.2022.03.003>
- Negara A., Jin G., Agrawal G. (2016). Enhancing Rock Property Prediction from Conventional Well Logs Using Machine Learning Technique-Case Studies of Conventional and Unconventional Reservoirs. *The Abu Dhabi International Petroleum Exhibition & Conference*, Abu Dhabi, UAE, SPE-183106-MS. <https://doi.org/10.2118/183106-MS>
- Pei X., Liu Y., Lin Z., Fan P., Mi L., Xue L. (2024). Anisotropic dynamic permeability model for porous media. *Petroleum Exploration and Development*, 51(1), pp. 193–202. [https://doi.org/10.1016/S1876-3804\(24\)60016-9](https://doi.org/10.1016/S1876-3804(24)60016-9)
- Ponomareva I.N., Martyushev D.A., Govindarajan S.K. (2022). A new approach to predict the formation pressure using multiple regression analysis: Case study from Sukharev oil field reservoir – Russia. *Journal of King University – Engineering Sciences*. <https://doi.org/10.1016/j.jksues.2022.03.005>
- Rashid M., Luo M., Ashraf U., Hussain W., Ali N., Rahman N., Hussain S., Martyushev D.A., Vo Thanh H., Anees A. (2023). Reservoir Quality Prediction of Gas-Bearing Carbonate Sediments in the Qadirpur Field: Insights from Advanced Machine Learning Approaches of SOM and Cluster Analysis. *Minerals*, 13(1), 29. <https://doi.org/10.3390/min13010029>
- Singh M., Makarychev G., Mustapha H., Voleti D., Akkur R., Daghar Kh.A., Mawlod A.A., Marzouki Kh.A., Shehab S., Maarouf A., Jundi O.E., Razouki A. (2020). Machine Learning Assisted Petrophysical Logs Quality Control, Editing and Reconstruction. *The Abu Dhabi International Petroleum Exhibition & Conference*, Abu Dhabi, UAE, SPE-202977-MS. <https://doi.org/10.2118/202977-MS>
- Sivagnanam M., Wang J., Gates I.D. (2017). On the fluid mechanics of slotted liners in horizontal wells. *Chemical Engineering Science*, 164, pp. 23–33. <https://doi.org/10.1016/j.ces.2017.01.070>
- Wang C.-C., Yang Y.-F., Han D.-L., Su M.-M., Hu R.-R. (2023). Influence of matrix physical properties on flow characteristics in dual network model. *Petroleum Science*, 20(4), pp. 2244–2252. <https://doi.org/10.1016/j.petsci.2023.06.006>
- Wang S., Xiang J., Wang X., Feng Q., Yang Y., Cao X., Hou L. (2024). A deep learning based surrogate model for reservoir dynamic performance prediction. *Geoenergy Science and Engineering*, 233, 212516. <https://doi.org/10.1016/j.geoen.2023.212516>
- Xie J. (2015). Slotted Liner Design Optimization for Sand Control in SAGD Wells. *SPE Thermal Well Integrity and Design Symposium*, Alberta, Canada, SPE-178457-MS. <https://doi.org/10.2118/178457-MS>
- Yang Y., Horne R.N., Cai J., Yao J. (2023). Recent advances on fluid flow in porous media using digital core analysis technology. *Advances in Geo-Energy Research*, 9(2), pp. 71–75. <https://doi.org/10.46690/ager.2023.08.01>
- Zakharov L.A., Martyushev D.A., Ponomareva I.N. (2022). Predicting dynamic formation pressure using artificial intelligence methods. *Journal of Mining Institute*, 253, pp. 23–32. <https://doi.org/10.31897/PMI.2022.11>
- Zhou X., Wei J., Zhao J., Zhang X., Fu X., Sultanov Sh., Gayubov A., Chen Y., Wang J. (2024). Study on pore structure and permeability sensitivity of tight oil reservoir. *Energy*, 288, 129632. <https://doi.org/10.1016/j.energy.2023.129632>

Сведения об авторах

Андрей Витальевич Соромотин – инженер 2-й категории отдела проектирования и мониторинга разработки Северной группы месторождений, филиал ООО «ЛУКОЙЛ-Инжиниринг» «ПермНИПИнефть» в г. Пермь Россия, 614015, Пермь, ул. Пермская, д. 3а
e-mail: s@soromotinav.ru

Дмитрий Александрович Мартюшев – доктор тех. наук, доцент, доцент кафедры Нефтегазовые технологии, Пермский национальный исследовательский политехнический университет
Россия, 614990, Пермь, пр-т Комсомольский, д. 29
e-mail: martyushevdi@inbox.ru

Александр Александрович Мелехин – канд. тех. наук, доцент кафедры Нефтегазовые технологии, Пермский национальный исследовательский политехнический университет
Россия, 614990, Пермь, пр-т Комсомольский, д. 29
e-mail: melehin.sasha@mail.ru

Статья поступила в редакцию 03.10.2023;
Принята к публикации 06.02.2024; Опубликована 30.03.2024

Prediction of Hydrodynamic Parameters of the State of the Bottomhole Zone of Wells Using Machine Learning Methods

A.V. Soromotin¹, D.A. Martyushev^{2*}, A.A. Melekhin²

¹LLC «LUKOIL-Engineering» “PermNIPneft” in Perm, Perm, Russian Federation

²Perm National Research Polytechnic University, Perm, Russian Federation

*Corresponding author: Dmitriy A. Martyushev, e-mail: martyushevdi@inbox.ru

Abstract. The relevance of the development of a methodology for the operational assessment of the bottom-hole formation zone (the permeability of the bottom-hole formation zone and the skin factor) is primarily due to economic considerations, since existing approaches to its definition based on hydrodynamic studies lead to shortages and increased risks of failure to ensure the output of the well. In this regard, the use of modern methods of working with big data, such as deep learning of artificial neural networks, will ensure monitoring of the condition of the bottom-hole zone of the well formation without stopping them for hydrodynamic tests, which will reduce losses for oil production enterprises. It will allow for operational analysis for effective and timely application of intensification technologies, enhanced oil recovery. The authors analyzed the existing methods for determining the bottom-hole characteristics of the formation and machine learning approaches in the direction of solving this problem. The article presents a methodology for the operational assessment of the state of the bottom-hole formation zone: the permeability of the near bottomhole zone (NBHZ) and the skin factor using artificial neural network training approaches based on geological, operational data and the results of interpretation of hydrodynamic studies on the example of sandstones of oil fields in the Perm Region. A fully connected neural network was used to predict the NBHZ permeability. The article presents the results of testing various neural network architectures: the number of layers and neurons in layers with the choice of the best one. Some techniques were used to prevent over-training of models. The author's methodology for assessing the skin factor of wells is proposed using a comprehensive analysis of the constructed statistical models and training models of artificial neural networks to solve the regression problem. In future studies, it is planned to use recurrent and convolutional neural networks to study the dynamic components of the formation of the bottom-hole formation zone and create an integrated approach to solve the problem.

Keywords: sandstone reservoir, bottom-hole formation zone, permeability, skin factor, machine learning, neural network

Recommended citation: Soromotin A.V., Martyushev D.A., Melekhin A.A. (2024). Prediction of Hydrodynamic Parameters of the State of the Bottomhole Zone of Wells Using Machine Learning Methods. *Georesursy = Georesources*, 26(1), pp. 109–117. <https://doi.org/10.18599/grs.2024.1.9>

References

Abdulaziz A.M., Ali M.K., Hafad O.F. (2022). Influences of Well Test Techniques and Uncertainty in Petrophysics on Well Test Results. *Energies*, 15(19), 7414. <https://doi.org/10.3390/en15197414>

Abobaker E., Elsanouse A., Khan F., Rahman M.A., Aborig A., Noah K. (2021). A New Evaluation of Skin Factor in Inclined Wells with Anisotropic Permeability. *Energies*, 14(17), 5585. <https://doi.org/10.3390/en14175585>

Alghazal M., Alshakhs M., Bouaouaja M. (2020). Technology integration to assessend-point oil saturation of the relative permeability curves. *International Petroleum Technology Conference*. Dhahran, Kingdom of Saudi Arabia. <https://doi.org/10.2523/iptc-19614-ms>

Alobaidi D.A. (2016). Permeability prediction in one of iraqi carbonate reservoir using hydraulic flow units and neural networks. *Iraqi Journal of Chemical and Petroleum Engineering*, 17(1), pp. 1–11. <https://doi.org/10.31699/IJCPE.2016.1.1>

Al-Obaidi S.H. (2016). Improve The Efficiency Of The Study Of Complex Reservoirs And Hydrocarbon Deposits-East Baghdad Field. *International Journal of Scientific & Technology Research*, 5(8), pp. 129–131.

Al-Obaidi S.H., Khalaf F.H. (2018). The Effects Of Hydro Confining Pressure On The Flow Properties Of Sandstone And Carbonate Rocks. *Journal of Geology & Geophysics*, 7(2), 327. <https://doi.org/10.4172/2381-8719.1000327>

Aygun A., Maulik R., Karakus A. (2023). Physics-informed neural networks for mesh deformation with exact boundary enforcement. *Engineering Applications of Artificial Intelligence*, 125, 106660. <https://doi.org/10.1016/j.engappai.2023.106660>

Bahaloo S., Mehrizadeh M., Najafi-Marghmaleki A. (2023). Review of application of artificial intelligence techniques in petroleum operations. *Petroleum Research*, 8(2), pp. 167–182. <https://doi.org/10.1016/j.ptlrs.2022.07.002>

Bennis M., Torres-Verdín C. (2019). Estimation of Dynamic Petrophysical Properties from Multiple Well Logs Using Machine Learning and Unsupervised Rock Classification. *SPWLA 60th Annual Logging Symposium*. The Woodlands, Texas, USA, SPWLA-2019-KKKK. https://doi.org/10.30632/T60ALS-2019_KKKK

Bennis M., Torres-Verdín C. (2023). Automatic Multiwell Assessment of Flow-Related Petrophysical Properties of Tight Gas Sandstones Based on The Physics of Mud-Filtrate Invasion. *SPE Reservoir Evaluation and Engineering*, 26(3), pp. 543–564. <https://doi.org/10.2118/214668-PA>

Bist N., Nair A., Yadav K., Sircar A. (2023). Diverting agents in the oil and gas industry: A comprehensive analysis of their origins, types, and applications. *Petroleum Research*. <https://doi.org/10.1016/j.ptlrs.2023.09.004>

Dong S.-Q., Zhong Z.-H., Cui X.-H., Zeng L.-B., Yang X., Liu J.-J., Sun Y.-M., Hao J.-R. (2023). A deep kernel method for lithofacies identification using conventional well log. *Petroleum Science*, 20(3), pp. 1411–1428. <https://doi.org/10.1016/j.petsci.2022.11.027>

Dong W., Wang X., Wang J. (2018). A new skin factor model for partially penetrated directionally-drilled wells in anisotropic reservoirs. *Journal of Petroleum Science and Engineering*, 161, pp. 334–348. <https://doi.org/10.1016/j.petrol.2017.11.062>

Dvoynikov M.V., Minaev Ya.D., Minibaev V.V., Kambulov E.Yu., Lamosov M.E. (2024). Technology for killing gas wells at managed pressure. *Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering*, 335(1), pp. 7–18. <https://doi.org/10.18799/24131830/2024/1/4315>

Eriavbe F.E., Okene U.O. (2019). Machine Learning Application to Permeability Prediction Using Log & Core Measurements: A Realistic Workflow Application for Reservoir Characterization. *SPE Nigeria Annual International Conference and Exhibition*, Lagos, Nigeria, SPE-198874-MS. <https://doi.org/10.2118/198874-MS>

Galkin V.I., Martyushev D.A., Ponomareva I.N., Chernykh I.A. (2021). Developing features of the near-bottomhole zones in productive formations at fields with high gas saturation of formation oil. *Journal of Mining Institute*, 249, pp. 386–392. <https://doi.org/10.31897/PMI.2021.3.7>

Gomaa S., Emara R., Mahmoud O., El-hoshoudy A.N. (2022). New correlations to calculate vertical sweep efficiency in oil reservoirs using nonlinear multiple regression and artificial neural network. *Journal of*

King Saud University – Engineering Sciences, 34(7), 368–375. <https://doi.org/10.1016/j.jksues.2021.07.010>

Gouda A., Attia A.M. (2022). Development of a new approach using an artificial neural network for estimating oil formation volume factor at bubble point pressure of Egyptian crude oil. *Journal of King Saud University – Engineering Sciences*, 36(1), pp. 72–80. <https://doi.org/10.1016/j.jksues.2022.08.001>

Hameed M.R.A., Hamd-Allah S.M. (2023). Studying the Effect of Permeability Prediction on Reservoir History Matching by Using Artificial Intelligence and Flow Zone Indicator Methods. *Iraqi Geological Journal*, 56(1E), pp. 9–21. <https://doi.org/10.46717/igj.56.1E.2ms-2023-5-12>

He Y., Liu Y., Cai H. (2022). Fine characterisation of remaining oil using timevarying numerical simulation: Experimental study. Characterisation in Model, and Application in QHD Oilfield. *Offshore Technology Conference Asia*. Virtual and Kuala Lumpur, Malaysia, OTC-31410-MS. <https://doi.org/10.4043/31410-ms>

Kantaatmadja B.P., Jiang L., Ralphia B. (2019). Hydrocarbon identification and evaluation in a bioturbated reservoir with next-generation pulsed neutron technology. *SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition*. Bali, Indonesia, SPE-196364-MS. <https://doi.org/10.2118/196364-ms>

Khairullin M.K., Shamsiev, M.N., Gadilshina, B.R., Morozov, P. E., Abdullin, A. I., Badertdinova, E.R. (2016). Determination of the Parameters of the Hole Bottom Zone of a Vertical Well from the Results of Thermodynamic Investigations. *Journal of Engineering Physics and Thermophysics*, 89(6), pp. 1449–1453. <https://doi.org/10.1007/s10891-016-1512-7>

Kubota L., Gioria R.S. (2022). Data-driven technique estimates skin factor and average pressure during oil-flowing periods. *Journal of Petroleum Science and Engineering*, 219, 111061. <https://doi.org/10.1016/j.petrol.2022.111061>

Li D., Zhou X., Xu Y., Wan Y., Zha W. (2023). Deep learning-based analysis of the main controlling factors of different gas-fields recovery rate. *Energy*, 285, 128767. <https://doi.org/10.1016/j.energy.2023.128767>

Liu S., Fan M., Lu D. (2023). Uncertainty quantification of the convolutional neural networks on permeability estimation from micro-CT scanned sandstone and carbonate rock image. *Geoenergy Science and Engineering*, 230, 212160. <https://doi.org/10.1016/j.geoen.2023.212160>

Liu X., Li D., Yang J., Zha W., Zhou Z., Gao L., Han J. (2020). Automatic well test interpretation based on convolutional neural network for infinite reservoir. *Journal of Petroleum Science and Engineering*, 195, 107618. <https://doi.org/10.1016/j.petrol.2020.107618>

Mahmoudi M., Fattahpour V., Nouri A., Yao T., Baudet B.A., Leitch M., Fermaniuk B. (2016). New Criteria for Slotted Liner Design for Heavy Oil Thermal Production. *SPE Thermal Well Integrity and Design Symposium*, Banff, Alberta, Canada, SPE-182511-MS. <https://doi.org/10.2118/182511-MS>

Matinkia M., Hashami R., Mehrad M., Hajsaeedi M. R., Velayati A. (2023). Prediction of permeability from well logs using a new hybrid machine learning algorithm. *Petroleum*, 9(1), pp. 108–123. <https://doi.org/10.1016/j.petlm.2022.03.003>

Negara A., Jin G., Agrawal G. (2016). Enhancing Rock Property Prediction from Conventional Well Logs Using Machine Learning Technique-Case Studies of Conventional and Unconventional Reservoirs. *The Abu Dhabi International Petroleum Exhibition & Conference*, Abu Dhabi, UAE, SPE-183106-MS. <https://doi.org/10.2118/183106-MS>

Pei X., Liu Y., Lin Z., Fan P., Mi L., Xue L. (2024). Anisotropic dynamic permeability model for porous media. *Petroleum Exploration and Development*, 51(1), pp. 193–202. [https://doi.org/10.1016/S1876-3804\(24\)60016-9](https://doi.org/10.1016/S1876-3804(24)60016-9)

Ponomareva I.N., Martyushev D.A., Govindarajan S.K. (2022). A new approach to predict the formation pressure using multiple regression analysis: Case study from Sukharev oil field reservoir – Russia. *Journal of King University – Engineering Sciences*. <https://doi.org/10.1016/j.jksues.2022.03.005>

Rashid M., Luo M., Ashraf U., Hussain W., Ali N., Rahman N., Hussain S., Martyushev D.A., Vo Thanh H., Anees A. (2023). Reservoir Quality Prediction of Gas-Bearing Carbonate Sediments in the Qadirpur Field: Insights from Advanced Machine Learning Approaches of SOM and Cluster Analysis. *Minerals*, 13(1), 29. <https://doi.org/10.3390/min13010029>

Singh M., Makarychev G., Mustapha H., Voleti D., Akkurt R., Daghar Kh.A., Mawlod A.A., Marzouqi Kh.A., Shehab S., Maarouf A., Jundi O.E., Razouki A. (2020). Machine Learning Assisted Petrophysical Logs Quality Control, Editing and Reconstruction. *The Abu Dhabi International Petroleum Exhibition & Conference*, Abu Dhabi, UAE, SPE-202977-MS. <https://doi.org/10.2118/202977-MS>

Sivagnanam M., Wang J., Gates I.D. (2017). On the fluid mechanics of slotted liners in horizontal wells. *Chemical Engineering Science*, 164, pp. 23–33. <https://doi.org/10.1016/j.ces.2017.01.070>

Wang C.-C., Yang Y.-F., Han D.-L., Su M.-M., Hu R.-R. (2023). Influence of matrix physical properties on flow characteristics in dual network model. *Petroleum Science*, 20(4), pp. 2244–2252. <https://doi.org/10.1016/j.petsci.2023.06.006>

Wang S., Xiang J., Wang X., Feng Q., Yang Y., Cao X., Hou L. (2024). A deep learning based surrogate model for reservoir dynamic performance prediction. *Geoenergy Science and Engineering*, 233, 212516. <https://doi.org/10.1016/j.geoen.2023.212516>

Xie J. (2015). Slotted Liner Design Optimization for Sand Control in SAGD Wells. *SPE Thermal Well Integrity and Design Symposium*, Alberta, Canada, SPE-178457-MS. <https://doi.org/10.2118/178457-MS>

Yang Y., Horne R.N., Cai J., Yao J. (2023). Recent advances on fluid flow in porous media using digital core analysis technology. *Advances in Geo-Energy Research*, 9(2), pp. 71–75. <https://doi.org/10.46690/ager.2023.08.01>

Zakharov L.A., Martyushev D.A., Ponomareva I.N. (2022). Predicting dynamic formation pressure using artificial intelligence methods. *Journal of Mining Institute*, 253, pp. 23–32. <https://doi.org/10.31897/PMI.2022.11>

Zhou X., Wei J., Zhao J., Zhang X., Fu X., Sultanov Sh., Gayubov A., Chen Y., Wang J. (2024). Study on pore structure and permeability sensitivity of tight oil reservoir. *Energy*, 288, 129632. <https://doi.org/10.1016/j.energy.2023.129632>

About the Authors

Andrey V. Soromotin – Engineer of the Department of Design and Monitoring of North group of fields, LLC «LUKOIL-Engineering» «PermNIPIneft» in Perm 3a, Permskaya st., Perm, 614015, Russian Federation
e-mail: s@soromotinav.ru

Dmitriy A. Martyushev – Dr. Sci. (Technical Sciences), Assistant Professor, Department of Oil and Gas Technologies, Perm National Research Polytechnic University 29, Komsomolskiy av., Perm, 614990, Russian Federation
e-mail: martyushevdi@inbox.ru

Alexander A. Melekhin – Cand. Sci. (Technical Sciences), Assistant Professor, Department of Oil and Gas Technologies, Perm National Research Polytechnic University 29, Komsomolskiy av., Perm, 614990, Russian Federation
e-mail: melehin.sasha@mail.ru

Manuscript received 3 October 2023;
Accepted 6 February 2024; Published 30 March 2024