

Оценка возможностей применения гибридного моделирования для оптимизации добычного потенциала нефтегазового месторождения

Пономарев Р.Ю., Мигманов Р.Р., Зязев Р.Р.
ООО «Тюменский нефтяной научный центр», Тюмень, Россия
ryponomarev@tncn.rosneft.ru

Аннотация

Рассматривается применение гибридного моделирования — прогнозирования и оптимизации параметров скважин с помощью комбинации гидродинамического и нейросетевого моделирования. Гидродинамическая модель служит эталонной моделью для обучения искусственной нейронной сети. Обученная нейросетевая модель используется в дальнейшем для решения задачи оптимизации на основе стохастического метода имитации отжига. Результатом являются оптимальные технологические параметры эксплуатации скважин, обеспечивающие максимальную добычу нефти. Подход позволяет сократить машинное время и повысить качество обоснования режимов работы скважин, необходимых для эффективной разработки месторождений.

Материалы и методы

Проведен анализ существующих методов применения нейросетевого моделирования в задачах разработки месторождений, определена архитектура искусственной нейронной сети для прогнозирования технологических параметров работы скважин, выполнены многовариантные расчеты на гидродинамической модели. Проведена апробация и оценка применения гибридного

моделирования в задаче оптимизации добычного потенциала нефтегазового месторождения.

Ключевые слова

нейросетевое моделирование, гидродинамическое моделирование, разработка месторождений

Для цитирования

Пономарев Р.Ю., Мигманов Р.Р., Зязев Р.Р. Применение гибридного моделирования для оптимизации добычного потенциала нефтегазового месторождения // Экспозиция Нефть Газ. 2023. № 5. С. 64–68. DOI: 10.24412/2076-6785-2023-5-64-68

Поступила в редакцию: 05.07.2023

OIL PRODUCTION

UDC 553.98 | Original Paper

Assessment of the possibilities of using hybrid modeling to optimize the production potential of an oil and gas field

Ponomarev R.Yu., Migmanov R.R., Ziazev R.R.
“Tyumen petroleum research center” LLC, Tyumen, Russia
ryponomarev@tncn.rosneft.ru

Abstract

The application of hybrid modeling — forecasting and optimization of well parameters using a combination of hydrodynamic and neural network modeling is considered. The hydrodynamic model serves as a reference model for training an artificial neural network. The trained neural network model is used in the future to solve the optimization problem based on the stochastic method of simulated annealing. The result is optimal technological parameters of well operation that ensure maximum oil production. The approach makes it possible to reduce machine time and improve the quality of justification of well operation modes necessary for effective field development.

Materials and methods

The analysis of the observed methods of neural network modeling in cases of field development was carried out, the architecture of the neural network was built to solve the problem, and multivariate calculations were carried out for the dynamics of the hydrodynamic

model. Approbation and evaluation of the use of combined modeling in the problem of estimating a mining deposit of a field was carried out.

Keywords

neural network modeling, hydrodynamic modeling, field development

For citation

Ponomarev R.Yu., Migmanov R.R., Ziazev R.R. Application of hybrid modeling to optimize the production potential of an oil and gas field. Exposition Oil Gas, 2023, issue 5, P. 64–68. (In Russ). DOI: 10.24412/2076-6785-2023-5-64-68

Received: 05.07.2023

Введение

Решение задач оптимизации разработки месторождений — многоэтапный и трудоемкий процесс, результативность которого чаще всего достигается путем математического моделирования. Качественное моделирование процессов разработки осложнено влиянием ряда факторов:

- неопределенность входных данных: часть характеристик месторождения можно определить лишь приближенно (усредненные характеристики пласта и др.), другая часть неизвестна;
- значительные временные затраты при расчете и реализации потенциальных вариантов оптимизации.

С другой стороны, с каждым днем все активнее внедряются методы искусственного интеллекта в задачах, связанных с прогнозированием и оптимизацией технологических процессов. В частности, к ним можно отнести задачи разработки месторождения, включая оптимизацию добычи. Искусственные нейронные сети (ИНС) позволяют устанавливать

взаимосвязи между параметрами и в дальнейшем использовать полученную информацию для прогнозирования. В некотором смысле ИНС становится цифровым двойником анализируемого объекта, а относительная простота вычислительной архитектуры ИНС в ряде случаев позволяет значительно сократить время расчета прогнозных вариантов.

Целью работы является исследование возможностей применения нейросетевых моделей для оптимизация процесса многовариантного расчета на полномасштабной ГДМ с применением методов гибридного моделирования и определения оптимальных технологических параметров работы скважин:

- даты переводов скважин под закачку;
- целевые приемистости нагнетательных скважин;
- режимы работы добывающих скважин.

При проведении оптимизационных расчетов в данной работе не учитываются технологические ограничения, связанные с передвижениями буровых станков и эксплуатацией скважин. Реальные ограничения могут быть учтены в дальнейших исследованиях. Исходная гидродинамическая модель считается идеальной, то есть описывает реальные физические процессы, происходящие на моделируемой залежи.

Постановка задачи

Для исследования возможностей применения гибридного моделирования выбрано месторождение Западной Сибири, разработка которого осложнена наличием подстилающей воды и газовой шапки (рис. 1). В этих условиях определение оптимальных технологических параметров работ скважин является трудоемкой задачей.

Характеристики рассматриваемого объекта (табл. 1):

- площадь с газовой шапкой;
- залежь куполообразная;
- рассматриваемая залежь не введена в разработку.

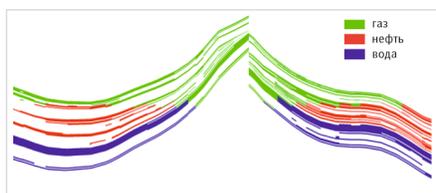


Рис. 1. Разрез через центр нефтегазовой залежи
Fig. 1. Section through the center of an oil and gas deposit

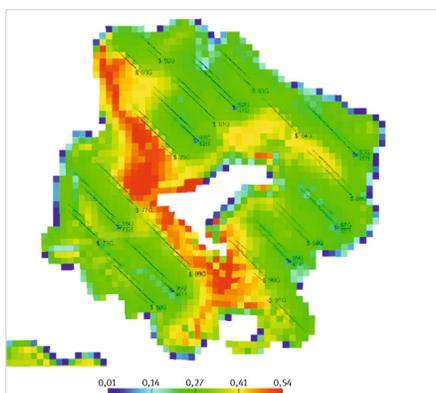


Рис. 2. Куб нефтенасыщенности залежи
Fig. 2. Oil saturation cube

Характеристика гидродинамической модели залежи (рис. 2):

- размерность — 69×65×77;
- фазы в модели: нефть, вода, газ;
- скважины: 14 добывающих и 7 нагнетательных скважин;
- время счета на 20 лет составляет около 2 минут.

Предпосылки применения нейросетевых технологий

Для достижения поставленных целей требуется инструмент, который позволяет воспроизвести физические процессы разработки аналогично гидродинамической модели (ГДМ), и за короткий промежуток времени провести многовариантные расчеты. Одним из возможных вариантов увеличения скорости расчетов является применение 2D гидродинамических прокси-моделей, однако создание таких моделей требует существенных трудозатрат.

Нейросетевое моделирование это метод машинного обучения, ключевой особенностью

которого является процесс самообучения на экспериментальные данные или, как в контексте поставленной задачи, на результаты расчетов ГДМ. Опираясь на теорему Колмагорова-Арнольда, в которой говорится, что любую непрерывную функцию p переменных можно получить с помощью операций сложения, умножения и суперпозиции из непрерывных функций одной переменной, и переложить теорему применительно к нейронным сетям, то можно утверждать, что ИНС способна воспроизвести любую монотонную функцию при достаточном количестве нейронов. Следовательно, ИНС может выступать как универсальный аппроксимирующий инструмент. При этом скорость вычисления нейросетевых моделей остается достаточно высокой за счет относительной простоты математической структуры сети.

Ограничением инструмента являются высокие требования к исходному объему данных. Для получения качественных результатов требуется достаточно разнообразная и достоверная обучающая выборка. Вторым

Табл. 1. Геолого-физические параметры залежи
Tab. 1. Geological and physical parameters of the deposit

№	Параметры	Размерность	Пласт Ю4
1	Средняя глубина залегания кровли	м	2 570
2	Абсолютная отметка ВНК	м	-2 700
3	Абсолютная отметка ГНК	м	-2 614
4	Тип залежи		пластово-сводовая, нефт. оторочка с газ. шапкой
5	Площадь нефте/газоносности	тыс. м ²	16 910/2 288
6	Средняя эфф. нефтенасыщенная толщина	м	5,5
7	Средняя эфф. газонасыщенная толщина	м	5,8
8	Средняя эфф. водонасыщенная толщина	м	5,9
9	Коэффициент пористости	доли ед.	0,16
10	Коэффициент нефтенасыщенности ЧНЗ	доли ед.	0,53
11	Коэффициент нефтенасыщенности ВНЗ	доли ед.	0,53
12	Коэффициент нефтенасыщенности пласта	доли ед.	0,53
13	Коэффициент газонасыщенности пласта	доли ед.	0,55
14	Проницаемость	мкм ²	0,0105
15	Коэффициент песчанности	доли ед.	0,23
16	Расчлененность	ед.	6
17	Начальное пластовое давление	Мпа	26,3
18	Плотность нефти в пластовых условиях	г/см ³	0,828
19	Плотность нефти в поверхностных условиях	г/см ³	0,883
20	Объемный коэффициент нефти	доли ед.	1,106
21	Содержание серы в нефти	%	1,2
22	Содержание парафина в нефти	%	4,08
23	Давление насыщения нефти газом	Мпа	11,5
24	Газосодержание	м ³ /т	108,4
25	Плотность конденсата в стандартных условиях	г/см ³	0,73
26	Вязкость газа в пластовых условиях	мПа·с	0,0207
27	Плотность газа в пластовых условиях	кг/м ³	0,1717
28	Коэффициент сверхсжимаемости газа	доли ед.	0,94
29	Вязкость воды в пластовых условиях	мПа·с	0,397
30	Плотность воды в поверхностных условиях	г/см ³	1,012
31	Сжимаемость породы	1/МПа×10 ⁻⁴	0,37
32	Вязкость нефти в пластовых условиях	мПа·с	4

ограничением является невозможность прогнозирования за пределами обучающей выборки.

Идея использования гибридного подхода при моделировании процессов фильтрации имеет широкое распространение: так, например, в работе [1] используется гибридная искусственная нейронная сеть и емкость-резистивная модель CRM (Capacitance-Resistive Models), которые позволяют получить упрощенную частично физически содержательную модель дебита жидкости, забойного давления, и доли нефти добывающих скважин в зависимости от уровней приемистости нагнетательных скважин. Искусственная нейронная сеть при этом используется для аппроксимации и прогнозирования обводненности продукции добывающей скважины, в зависимости от уровней закачки воды в нагнетательной скважине. Полученная гибридная модель применяется для решения ограниченного круга задач, а именно задач управления заводнением.

В другой работе [2] предлагается метод проектирования гидродинамических МУН с помощью интеграции решений, полученных с помощью методов машинного обучения, в традиционную гидродинамическую модель. Ключевой особенностью метода является использование алгоритмов машинного обучения для расчета оптимального распределения закачки на месторождении с последующей верификацией результатов в адаптированной гидродинамической модели. Данный подход, как и предыдущий, решает одну конкретную задачу разработки, связанную с оптимальным распределением закачки на месторождении.

Применение ИНС для расчета технологических параметров разработки месторождений возможно в формате суррогатной модели пласта SRM (Surrogate Reservoir Model) [3]. Данная модель функционирует как модель ИНС, в которой полностью имитируются численные решения, полученные с помощью полноценного гидродинамического моделирования. На практике полученные суррогатные модели применяют с целью достижения максимальной добычи нефти за счет регулирования режимов работы уже действующего фонда нефтяных скважин. В нашем представлении заявленный метод является перспективным и может быть расширен для решения большого круга промышленных задач, связанных, например, с проектированием и разработкой месторождений.

В нашей работе мы применяем, исследуем и расширяем применимость методов суррогатного моделирования, предложенного

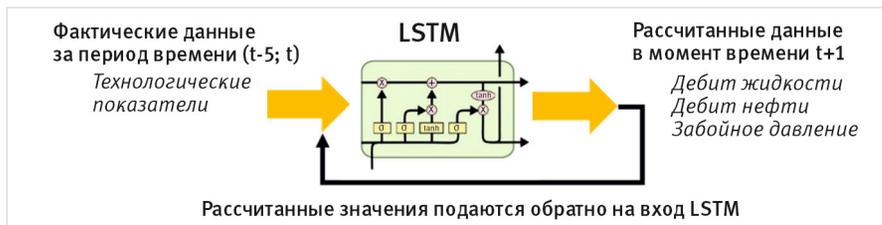


Рис. 3. Схема прогнозирования (авторегрессия)
Fig. 3. Prediction (autoregression)

в работе [4]. Ключевыми особенностями нашего подхода является применение методов нейросетевого моделирования (а именно модели LSTM) в качестве суррогатной модели для имитации работы ГДМ. Также мы расширяем и исследуем область применения методов искусственного интеллекта для решения задач оптимизации проектирования еще не запущенных в разработку месторождений.

Создание обучающей выборки

Для применения нейросетевого моделирования необходимо создать выборку прогнозных вариантов, на основе которых будет происходить обучение ИНС. Распределение параметров в обучающей выборке создавалась с помощью корпоративного ПМ «Rexlab», прогнозные варианты рассчитывались на ГДМ в корпоративном ПО «РН-КИМ».

Описание вариантов:

- скважины вводятся каждый месяц в случайном порядке;
- характер скважин остается неизменным (нагнетательные скважины без отработки);
- забойное давление добывающих скважин варьируется в пределах от 50 до 150 атм.;
- приемистость нагнетательных скважин задается в пределах от 400 до 1 000 м³/сут.
- общее количество вариантов — 50.

Такие параметры, как забойное давление добывающих скважин и приемистость нагнетательных, в каждой выборке подбираются с помощью латинского гиперкуба. Латинский гиперкуб — один из стандартных алгоритмов планирования эксперимента, позволяющий сгенерировать набор случайных вариантов, которые характеризуются максимальным разнообразием абсолютных значений параметров и большим количеством неповторяющихся сочетаний сгенерированных величин.

Подготовка данных и результаты обучения

Перед обучением все исходные данные нормализуются по правилу Z-нормализации

для каждой скважины по всем вариантам. Нормализованная оценка величины x рассчитывается по формуле:

$$z = \frac{x - \bar{X}}{S_x}, \quad (1)$$

где \bar{X} — среднее значение, S_x — стандартное отклонение для множества данных x . Z-нормализация позволяет привести физические величины в единый цифровой диапазон и упростить процесс обучения нейронной сети.

Данные, подаваемые на вход нейронной сети:

- для добывающих скважин: дебит нефти, забойное давление;
- для нагнетательных скважин: приемистость.

Обучающая выборка ИНС состоит из 46 вариантов, тестовая выборка — из 4 вариантов. Тестовые варианты выбраны таким образом, чтобы не выходить за пределы обучающей выборки.

Для задачи прогнозирования технологических показателей скважин реализована авторегрессионная нейросетевая модель LSTM, для которой текущее значение зависит от предыдущих его элементов временного ряда. Входным вектором модели является предыстория динамики технологических показателей, а выходным вектором — дебит нефти по добывающим скважинам на следующий временной шаг. В процессе нейросетевого моделирования дебит нефти рассчитывается и передается обратно на вход ИНС для генерации следующего временного шага. Принципиальная схема представлена на рисунке 3.

Процесс обучения модели является ключевой процедурой нейросетевого моделирования. Обучение проводится путем оптимизации весовых коэффициентов с целью достижения минимального расхождения между рассчитанными и фактическими значениями дебитов нефти. Однако важно

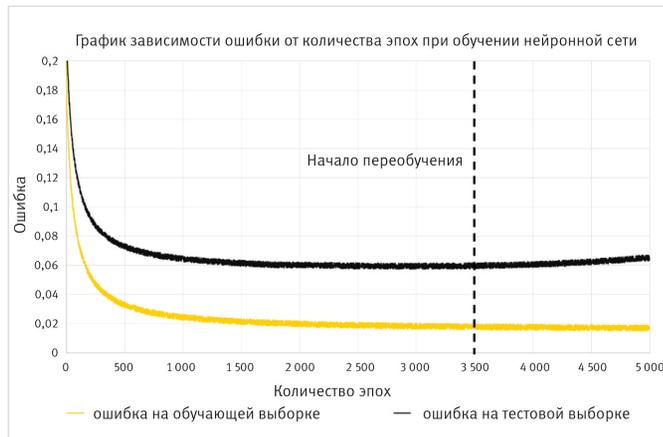


Рис. 4. Пример переобучения нейронной сети
Fig. 4. An example of retraining a neural network

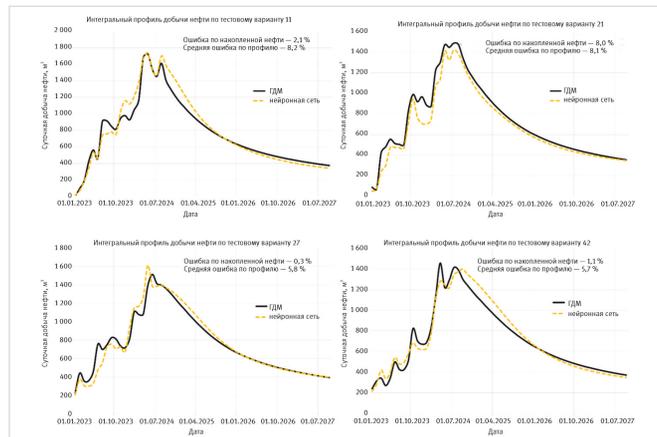


Рис. 5. Интегральный профиль по тестовым вариантам № 11, 21, 27 и 42
Fig. 5. Integral profile according to test variants № 11, 21, 27 and 42

не допустить переобучения модели: при переобучении ИНС теряет способность корректно прогнозировать элементы временного ряда, поскольку буквально «запоминает» обучающую выборку. Чтобы контролировать этот процесс, обучающая выборка разбивается на два множества — обучающую и валидационную. Далее проводится перекрестная проверка ошибки на обоих множествах: если на валидационном множестве ошибка начинает расти, а на обучающем продолжает снижаться, то это является индикатором начала переобучения модели, и процесс обучения следует остановить (рис. 4).

Для контроля качества прогнозирования были рассчитаны тестовые варианты, не входящие в обучающую выборку. В целом, ИНС удовлетворительно воспроизводит результаты ГДМ (рис. 5–7), однако на некоторых скважинах наблюдаются периоды с ошибкой прогнозирования выше среднего (более 10 %). Максимальная ошибка, как видно из графиков, формируется в начале прогнозирования, когда добыча нефти на ГДМ претерпевает резкие изменения (пики и спады). В периоды снижения добычи нефти отмечается минимизация ошибки в силу монотонности динамики.

По итогам анализа тестовых вариантов можно сделать вывод, что прогностическая способность модели удовлетворительная со средней ошибкой не более 10 %.

Полный цикл создания обученной нейросетевой модели для имитации работы полномасштабной ГДМ составляет 24,5 часа, в том числе 12,5 часа на расчет обучающей выборки и 12 часов на обучение нейросетевой модели.

Постановка и решение задачи оптимизации

Целью задачи оптимизации является определение оптимальных режимов работы скважин (дата ввода, запускные приемистости, режимы добывающих скважин) для максимизации целевой функции. Целевая функция определена как суммарные отборы нефти на периоде прогнозирования. Для поиска оптимальных решений используются различные математические оптимизационные алгоритмы, которые позволяют найти максимум за ограниченное количество итераций. В нашей работе используется метод имитации отжига. Данный метод имеет ряд преимуществ:

- метод прост в реализации;
- не требуются дополнительные вычислительные затраты для оптимизации.

Однако метод не гарантирует нахождение глобального максимума и поэтому

рекомендуется запускать расчет несколько раз.

Для количественной оценки успешности оптимизации был определен базовый вариант разработки из обучающей выборки — вариант с наименьшими забойными давлениями. Данный вариант является тривиальным, с точки зрения разработки, для достижения максимальных отборов нефти. Целью работы оптимизатора является расчет более эффективных распределений забойного давления и оптимальных запусков добывающих и нагнетательных скважин для достижения больших отборов нефти, чем обеспечивает базовый тривиальный вариант.

В результате работы алгоритма оптимизации были получены даты ввода, запускные приемистости и режимы добывающих скважин (табл. 2). Полученные режимы были загружены в ГДМ и рассчитан прогнозный оптимальный вариант (рис. 8).

Табл. 2. Результаты решения оптимизационной задачи
Tab. 2. Results of solving the optimization problem

Скв.	Дата ввода		Приемистость, м ³ /сут		Рзаб, атм	
	Базовый	Оптим.	Базовый	Оптим.	Базовый	Оптим.
1	01.02.2023	01.02.2023	–	–	50	50
2	01.06.2024	01.01.2023	–	–	50	70
3	01.04.2023	01.09.2024	–	–	50	60
4	01.12.2023	01.08.2024	–	–	50	50
5	01.03.2023	01.07.2024	–	–	50	60
6	01.09.2024	01.06.2024	–	–	50	60
7	01.10.2023	01.03.2023	–	–	50	50
8	01.01.2024	01.05.2024	–	–	50	50
9	01.07.2023	01.04.2023	–	–	50	150
10	01.01.2023	01.04.2024	–	–	50	50
11	01.08.2024	01.05.2023	–	–	50	150
12	01.03.2024	01.03.2024	–	–	50	60
13	01.11.2023	01.02.2024	–	–	50	60
14	01.08.2023	01.01.2024	–	–	50	50
15	01.06.2023	01.12.2023	1 000	1 000	–	–
16	01.05.2023	01.11.2023	1 000	1 000	–	–
17	01.05.2024	01.10.2023	1 000	1 000	–	–
18	01.07.2024	01.06.2023	1 000	1 000	–	–
19	01.04.2024	01.11.2023	1 000	1 000	–	–
20	01.09.2023	01.12.2023	1 000	1 000	–	–
21	01.02.2024	01.07.2023	1 000	1 000	–	–

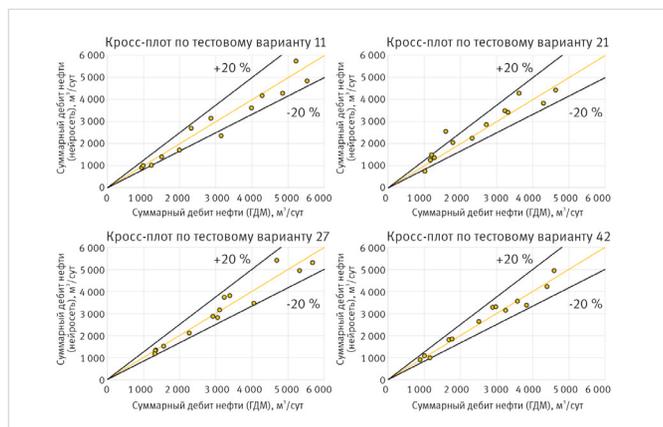


Рис. 6. Кросс-плот по тестовому варианту 42
Fig. 6. Cross-plot according to test case 42

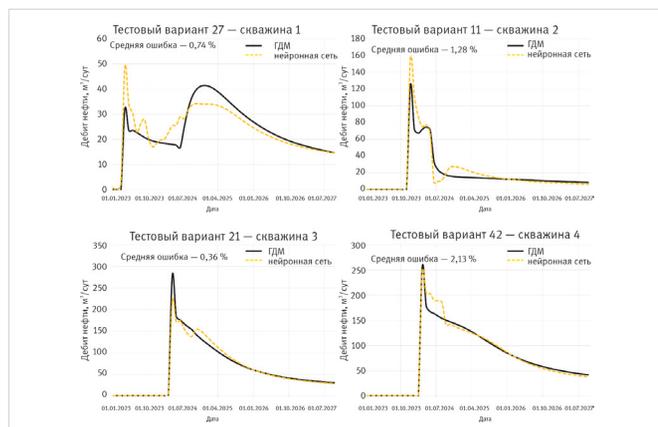


Рис. 7. Поскважинный результат прогнозирования данных тестового варианта
Fig. 7. Well test case data prediction result

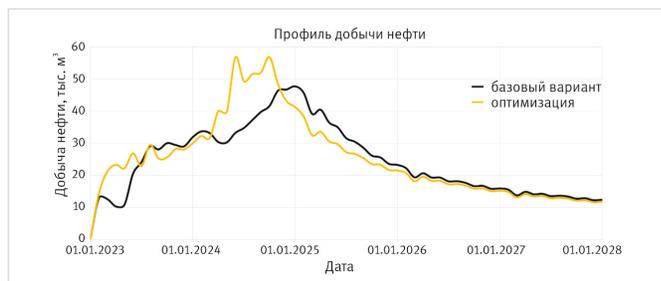


Рис. 8. Профиль добычи нефти за 5 лет базового варианта и варианта с оптимизацией
Fig. 8. Oil production profile for 5 years of the base case and the case with optimization

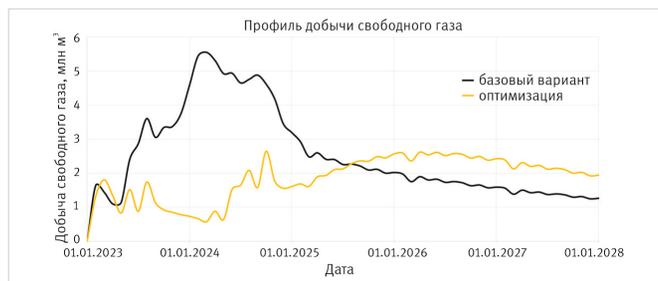


Рис. 9. Профиль добычи газа за 5 лет базового варианта и варианта с оптимизацией
Fig. 9. Gas production profile for 5 years of the base case and the case with optimization

производимые на полномасштабной ГДМ, и тем самым упрощает процесс решения различных задач оптимизации и обоснования оптимальных режимов работы добывающих скважин.

Выводы

- Метод нейросетевого моделирования позволяет расширить применимость традиционной ГДМ в задачах разработки нефтегазовых месторождений;
- Решение задачи оптимизации технологических параметров работы скважин на рассматриваемой залежи позволило получить прирост по добыче нефти за 5 лет на 45 тыс. тонн (3% относительно базового варианта);
- Итоговое сокращение времени, с учетом формирования обучающей выборки и обучения модели LSTM, составляет 225 часов (в 10 раз быстрее относительно прямого оптимизационного расчета на полномасштабной ГДМ);
- Предложенный подход может быть использован для дальнейшего развития

направления по применению нейросетевого моделирования в нефтегазовой промышленности.

Литература

1. Бриллиант Л.С., Завьялов А.С., Данько М.Ю. Способ оперативного управления заводнением пластов. Патент RU 2715593 С1. Заявитель и пантообладатель ООО «ТИНГ». 2020.
2. Бриллиант Л.С., Завьялов А.С., Данько М.Ю., Андонов К.А., Шпуров И.В., Браткова В.Г., Давыдова А.В. Интеграция методов машинного обучения и геолого-гидродинамического моделирования при проектировании разработки месторождений // Нефтяное хозяйство. 2022. № 3. С. 48–53.
3. Shahab D. Mohaghegh, Fareed Abdulla. Production management decision analysis using ai-based proxy modeling of reservoir simulations – a look-back case study. SPE Annual Technical Conference and exhibition, Amsterdam, The Netherlands, October 2014, SPE-170664-MS. (In Eng).
4. Qin He, Shahab D. Mohaghegh, Zhikun Liu. Reservoir simulation using smart proxy in SACROC unit – case study. SPE Eastern Regional Meeting, Canton, Ohio, USA, September 2016. SPE-184069-MS. (In Eng).

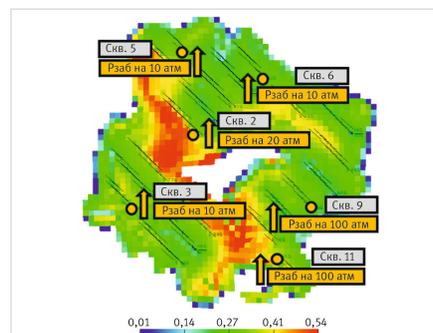


Рис. 10. Карта нефтенасыщенности с учетом оптимизации по скважинам
Fig. 10. Oil saturation map taking into account optimization by wells

ENGLISH

Results

The paper has tested a hybrid modeling method based on the use of neural network modeling as a digital twin of a full-fledged hydrodynamic model. Hybrid modeling makes it possible to improve the quality of the process of substantiating the operating modes of wells necessary for efficient field development.

Conclusions

- The neural network modeling method allows to expand the applicability of traditional GDM in the tasks of oil and gas field development;

References

1. Method of operative control of water flooding of formations. Patent RU 2715593 C1. "Tyumen oil and gas institute" LLC (RU), 2020. (In Russ).
2. Brilliant L.S., Zavialov A.S., Danko M.Yu., Andronov K.A., Shpurov I.V., Bratkova V.G., Davydov A.V. Integration of machine learning methods and geological and hydrodynamic modeling in field development design. Oil industry, 2022, issue 3, P. 48–53. (In Russ).
3. Shahab D. Mohaghegh, Fareed Abdulla. Production management decision analysis using ai-based proxy modeling of reservoir simulations – a look-back case study. SPE Annual Technical Conference and exhibition, Amsterdam, The Netherlands, October 2014, SPE-170664-MS. (In Eng).
4. Qin He, Shahab D. Mohaghegh, Zhikun Liu. Reservoir simulation using smart proxy in SACROC unit – case study. SPE Eastern Regional Meeting, Canton, Ohio, USA, September 2016. SPE-184069-MS. (In Eng).

- Solving the problem of optimizing the technological parameters of the wells in the considered deposit allowed to obtain an increase in oil production over 5 years by 45 thousand tons (3% relative to the basic option);
- The final reduction in time, taking into account the formation of the training sample and the training of the LTM model, is 225 hours (10 times faster relative to the direct optimization calculation on a full-scale GDM);
- The proposed approach can be used for further development of the application of neural network modeling in the oil and gas industry.

ИНФОРМАЦИЯ ОБ АВТОРАХ | INFORMATION ABOUT THE AUTHORS

Пономарев Роман Юрьевич, главный специалист, ООО «Тюменский нефтяной научный центр», Тюмень, Россия
Для контактов: ryponomarev@tnnc.rosneft.ru

Ponomarev Roman Yurievich, chief specialist, "Tyumen petroleum research center" LLC, Tyumen, Russia
Corresponding author: ryponomarev@tnnc.rosneft.ru

Мигманов Руслан Рамилевич, главный специалист, ООО «Тюменский нефтяной научный центр», Тюмень, Россия

Migmanov Ruslan Ramilevich, chief specialist, "Tyumen petroleum research center" LLC, Tyumen, Russia

Зиаев Рамиль Ришатович, заместитель начальника управления, ООО «Тюменский нефтяной научный центр», Тюмень, Россия

Ziaev Ramil Rishatovich, deputy head of department, "Tyumen petroleum research center" LLC, Tyumen, Russia