

Прогнозирование распределения температуры по стволу нефтяных скважин при пароциклической обработке

Степанов В.А., Ясницкий Л.Н.

ООО «Нейрософт глобал», Пермь, Россия
svamail@list.ru

Аннотация

Основным источником получения информации о степени прогрева нефтяного пласта и эффективности пароциклической обработки скважин являются геофизические исследования, заключающиеся в измерении температуры в стволе скважины с помощью опускаемого в скважину геофизического прибора. Это довольно трудоемкий и не всегда успешный процесс. В качестве альтернативы в настоящей статье делается попытка разработки инженерного программного продукта, способного прогнозировать распределение температуры в скважине и, таким образом, частично либо полностью заменить исследования скважины с помощью опускаемого прибора. Нейронная сеть, лежащая в основе инженерного продукта, обучалась на данных о скважинах Усинского месторождения. В статье отмечается, что возможность прогнозирования распределения температуры в скважинах может позволить инженерам находить и реализовывать наиболее рациональные режимы пароциклической обработки.

Материалы и методы

При проектировании, генерации, тестировании нейронных сетей и нейросетевом моделировании использовались программные инструменты, наработки и опыт научной школы Пермского государственного национального исследовательского университета. Для обучения нейронных сетей использовался датасет, созданный

на основании данных пароциклической обработки 50 скважин Усинского месторождения.

Ключевые слова

пароциклическая обработка, ГИС 55, Усинское месторождение, нефть, нефтяной пласт, скважина, прогнозирование, нейронная сеть, температура

Благодарности

Исследование выполнено при финансовой поддержке Фонда содействия инновациям (Россия): договор 4469ГC1/72542 от 15 февраля 2022 г.

Для цитирования

Степанов В.А., Ясницкий Л.Н. Прогнозирование распределения температуры по стволу нефтяных скважин при пароциклической обработке // Экспозиция Нефть Газ. 2023. № 3. С. 69–73. DOI: 10.24412/2076-6785-2023-3-69-73

Поступила в редакцию: 15.05.2023

AUTOMATION

UDC 65.011.56 | Original Paper

Prediction of temperature distribution along the oil wells during steam cycling

Stepanov V.A., Yasnitsky L.N.

“Neurosoft Global” LLC, Perm, Russia
svamail@list.ru

Abstract

One of the main sources of obtaining information about the degree of heating of the oil reservoir and the effectiveness of steam cyclic treatment of wells is geophysical research, which consists in measuring the temperature in the wellbore using a descent geophysical instrument. This is a rather laborious and not always successful process. As an alternative, this article attempts to develop an engineering software product capable of predicting the temperature distribution in a well and thus partially or completely replace the downhole survey. The neural network underlying the engineering product was trained on data from the wells of the Usinskoye field. The article notes that forecasting the temperature distribution in wells can allow engineers to find and implement the most rational modes of steam cycling treatment.

Materials and methods

When designing, generating, testing neural networks and neural network modeling, software tools, developments and experience of the scientific school of the Perm State National Research University were used. To train neural networks, a dataset was used, created on the basis of steam cycling data from 50 wells in the Usinskoye field.

Keywords

steam cycling, GIS 55, Usinskoye field, oil, oil reservoir, well, forecasting, neural network, temperature

For citation

Stepanov V.A., Yasnitsky L.N. Prediction of temperature distribution along the oil wells during steam cycling. Exposition Oil Gas, 2023, issue 3, P. 69–73. (In Russ). DOI: 10.24412/2076-6785-2023-3-69-73

Received 15.05.2023

Введение

Одним из основных источников получения информации о степени прогрева нефтяного пласта и эффективности закачки пара при пароциклической обработке (ПЦО) являются геофизические исследования скважин (ГИС), заключающиеся в измерении температуры, давления и определении других характеристик пара посредством исследования скважины с помощью опускаемого в скважину геофизического прибора.

Однако следует отметить, что проведение ГИС имеет свои проблемы. Это довольно трудоемкий и не всегда успешный процесс. Так, например, на Усинском месторождении за 2020 г. из 105 проведенных ГИС 38 % оказались неинформативны. Причиной низкого охвата исследованиями является, как правило, отсутствие возможности спуска прибора ГИС на глубину более 500 м. Интервалы же перфорации обычно находятся значительно глубже. Поэтому такие исследования не характеризуют степень прогрева нефтяного пласта. Программных же инструментов, которые бы позволяли прогнозировать распределение теплофизических характеристик закачиваемого пара вглубь ствола скважины без применения прибора ГИС, пока не существует.

В связи с этим цель нашего исследования состоит в создании программного инструмента, способного выполнять прогнозирование распределения температуры по стволу скважины и, таким образом, частично либо полностью заменить трудоемкие и малоэффективные ГИС.

Научная новизна и актуальность наших исследований заключается в применении современного математического аппарата нейронных сетей, который, по-видимому, ранее для этих целей не применялся.

Следует, тем не менее, отметить, что методы машинного обучения уже давно и успешно используются в задачах прогнозирования объемов добычи нефти и газа, однако не затрагивая моделирования процессов ПЦО. Так, в работе [1] предложен метод прогнозирования дебита нефти с использованием искусственной нейронной сети. Авторы работы [2] решают задачу прогнозирования суточных объемов добычи газа на горизонтальных скважинах. В работе [3] сообщается об успешном применении аппарата нейросетевого моделирования для прогнозирования дебита нефти на месторождении Волве в Норвегии. Авторы работы [4] применили метод нейросетевого моделирования для прогнозирования динамического забойного давления в нефтяных скважинах с целью оптимизации добычи нефти. Пользуясь методами машинного обучения, включая регрессию, метод опорных векторов и нейронные сети, авторы [5] создали модель, прогнозирующую дебит нефти в зависимости от времени и других параметров.

Таким образом, мы видим, что методы машинного обучения, в частности нейронные сети, довольно широко и успешно применяются в задачах прогнозирования и оптимизации объемов добычи нефти. Однако случаев применения этих прогрессивных методов в задачах моделирования ПЦО нам обнаружить не удалось. Тем более нам не удалось найти работы, в которых метод нейросетевого моделирования использовался бы для выявления закономерностей процесса ПЦО, знание которых необходимо инженерам для

его оптимального проектирования и применения на скважинах.

Целью настоящего исследования является разработка математической модели процесса ПЦО на основе нейронных сетей с последующим применением разработанной модели для выявления закономерностей этого процесса. Целью исследования является также создание на основе разработанных нейронных сетей инженерного программного продукта, предназначенного для поддержки принятия решений инженерами-нефтяниками, занимающихся проектированием и проведением ПЦО.

Создание нейронной сети

Для достижения этой цели нам были предоставлены данные результатов ГИС по 51-й скважине Усинского месторождения. В этом множестве данных 20 параметров было принято в качестве входных параметров создаваемой нейросетевой модели. Среди этих двадцати входных параметров были общие характеристики скважины, время года, в котором проводились ПЦО и ГИС, а также характеристики пара на выходе парогенераторной установки (ПГУ) и на уровне устья скважин.

В качестве выходного параметра нейронной сети была принята температура, снимаемая с прибора, ГИС по мере его спуска в скважину. С каждой скважины было снято в среднем по 1500 таких замеров, таким образом все множество (Датасет) составило $51 \times 1500 = 76\,500$ примеров.

Из собранного набора данных было выделено тестовое множество, состоящее из 1 500 примеров, относящихся к 51-й скважине. Из оставшегося множества ($76\,500 - 1\,500 = 75\,000$ примеров) было удалено приблизительно 50 примеров, являющихся выбросами статистической информации, которые возникли из-за погрешностей измерений приборов ГИС. Выбросы были обнаружены с помощью авторской методики [6]. В основе этой методики лежит свойство нейронных сетей, имеющих небольшое количество степеней свободы, плохо обучаться на примерах, являющихся статистическими выбросами. После применения процедуры обучения такой нейронной сети более высокая погрешность обучения концентрируется на тех примерах, которые выпадают из общих закономерностей моделируемой предметной области, т.е. являются статистическими выбросами. Эта повышенная погрешность и является индикатором того, что данное наблюдение является ошибочным.

Остальные $75\,000 - 50 = 74\,950$ примеров были случайным образом разделены на обучающее множество 71 950 примеров и валидирующее множество 3 000 примеров.

Для генерации, обучения, валидации и тестирования нейронных сетей мы использовали собственный программный инструмент «Нейросимулятор 5.1» [8], который хорошо зарекомендовал себя при выполнении многих наших проектов [7]. С помощью этого программного инструмента были сгенерированы нейронные сети различной архитектуры. В процессе валидации с помощью программного инструмента «Нейросимулятор 5.0» была подобрана оптимальная для данной задачи архитектура нейронной сети, состоящей из 20 входных нейронов, одного выходного нейрона с линейной активационной функцией и двух скрытых слоев с восемью и тремя нейронами с активационными функциями в форме гиперболического тангенса.

В результате нейросетевых вычислений было получено распределение температуры по стволу тестовой скважины № 51 (рис. 1) в сравнении с данными измерений с помощью прибора ГИС. Коэффициент детерминации данных R^2 между данными ГИС-исследований и прогнозными значениями нейросети составил 0,988, максимальная абсолютная ошибка составила $37\text{ }^\circ\text{C}$, а средняя абсолютная ошибка — $12,4\text{ }^\circ\text{C}$. Дополнительные проверки нейронных сетей, в которых вместо скважины № 51 в качестве тестовой поочередно выбирались другие скважины, не показали сколько-нибудь заметного увеличения погрешностей, превышающих указанные выше числовые значения. Всего таких кросс-валидационных проверок было проведено более двадцати.

Анализируя прогнозные результаты вычислений нейросети (рис. 1), можно обратить внимание на незначительные скачки температуры в районах перфорации, обнаруженные нейросетевой моделью. Небольшое локальное повышение температуры в этих районах можно объяснить тем, что здесь часть пара уходит через перфорационные

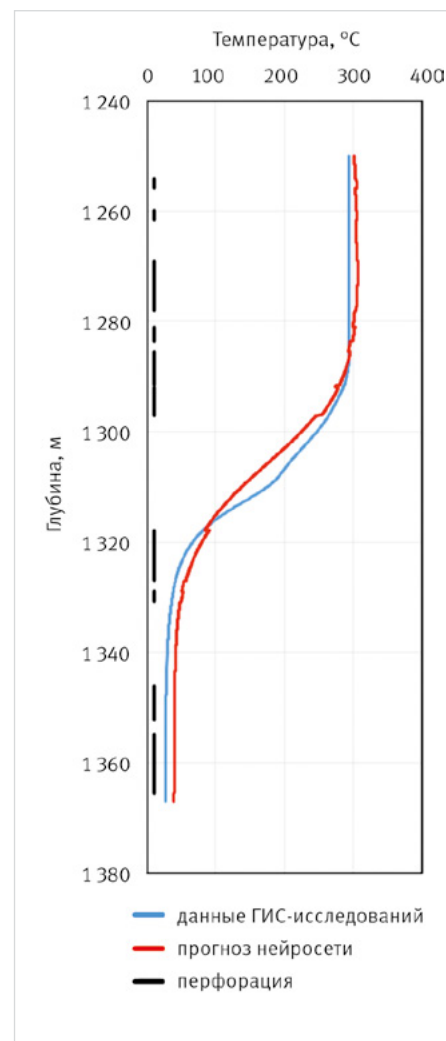


Рис. 1. Распределения температуры по стволу тестовой скважины № 51, полученные в результате прогнозных вычислений нейросети и измерений с помощью прибора ГИС
Fig. 1. Temperature distributions along the borehole of test well № 51, obtained as a result of predictive calculations of the neural network and measurements using a well logging tool

отверстия в пласт, вызывая его локальный разогрев.

Приведенные здесь результаты тестирования нейронной сети можно признать удовлетворительными, если учесть, что мы решили задачу, возможность найти решение которой с самого начала представлялась сомнительной. Действительно, мы научились с точностью до 37 °С предсказывать температуру в скважине на глубинах более 1 250 м, имея в своем распоряжении минимум информации: общие характеристики скважины, информацию о времени года и параметры закачиваемого пара, измеренные на поверхности земли на уровне устья скважины. Таким образом, мы подтвердили саму принципиальную возможность такого прогнозирования.

Отсюда следует полезный в практическом отношении вывод. Теперь инженеры-нефтяники могут частично или даже полностью отказаться от применения трудоемкой и не всегда эффективной технологии спуска прибора ГИС в скважину, заменив эту процедуру вычислениями нейронной сети.

Компьютерные эксперименты

А теперь еще раз обратим внимание на то, что нам удалось создать математическую модель, которая показала приемлемую погрешность прогнозирования температуры в любой точке тестовой скважины. Это значит, что нейронная сеть, в пределах своей погрешности (37 °С), адекватна моделируемому процессу и ведет себя так же, как вело бы себя моделируемое явление в различных ситуациях. Значит, над нейронной сетью, как над моделью процесса ПЦО, можно ставить компьютерные эксперименты. Можно, виртуально изменяя входные параметры, получать ответ на вопрос: «что будет, если изменить тот или иной параметр ПЦО?».

В качестве примера проведения виртуальных компьютерных экспериментов была выбрана скважина № 51, характеристики и условия проведения ПЦО которой приведены в таблице 1.

С помощью нейросетевых вычислений получен результат (рис. 2а), отвечающий на вопрос, что было бы с распределением температуры по стволу скважины, если бы «Показания счетчика расхода пара на устье», а вместе с ним и «Расход пара по счетчику на парогенераторной установке (ПГУ)», а также «Расход пара на ПГУ на одну скважину», «Давление пара на устье» и «Давление пара на ПГУ» одновременно увеличились бы в 1,25 раза или уменьшились бы во столько же раз. Исходное распределение температуры, соответствующее табличным данным (табл. 1), показано красным цветом (рис. 2а). Зеленым цветом отмечено распределение температуры при увеличении всего указанного комплекса параметров в 1,25 раза, а синим цветом показано распределение температуры, если бы все значения этого комплекса параметров уменьшились бы в 1,25 раза. Как видно из приведенных результатов (рис. 2а), увеличение давления и расхода пара в 1,25 раза значительно улучшает прогрев скважины, тогда как соответствующее уменьшение этих параметров приводит к значительному понижению степени прогрева скважины.

Аналогично с помощью нейросети получен результат (рис. 2б), отвечающий на вопрос, что было бы с распределением температуры по стволу скважины, если бы «День проведения ГИС с начала закачки пара» и «Объем закачанного пара на момент ГИС» одновременно увеличились бы в 1,95 раза или уменьшились во столько раз. Исходное распределение температуры показано

красным цветом. Зеленым цветом отмечено распределение температуры при увеличении этих параметров в 1,95 раза, а синим цветом показано распределение температуры, если бы значения этих параметров уменьшились бы в 1,95 раза. Как видно из полученных результатов (рис. 2б), увеличение количества дней с начала закачки пара при одновременном увеличении объема закачанного пара в 1,95 раза значительно улучшает прогрев скважины, тогда как соответствующее уменьшение этих параметров приводит к такому же сильному понижению степени прогрева скважины.

Аналогично получен результат (рис. 2в), отвечающий на вопрос, что было бы с распределением температуры по стволу скважины, если бы «Сухость пара на ПГУ» увеличилась бы в 1,2 раза или уменьшилась бы во столько же раз. Исходное распределение температуры показано красным цветом. Зеленым цветом показано распределение температуры при увеличении сухости пара на ПГУ в 1,23 раза, а синим цветом показано распределение температуры, если бы значения сухости пара на ПГУ уменьшились бы в 1,12 раза. Как видно (рис. 2в), увеличение сухости пара на ПГУ в 1,23 раза незначительно улучшает прогрев скважины, тогда как уменьшение этого параметра в 1,12 раза приводит к незначительному понижению степени прогрева скважины.

Итоги

Из приведенных в предыдущем разделе результатов виртуальных компьютерных экспериментов следуют интересные практические выводы:

- путем увеличения давления и расхода нагнетаемого пара, например в 1,25 раза, на скважине № 51 можно добиться значительного увеличения прогрева скважины (рис. 2а);
- путем увеличения длительности процесса ПЦО, например в 1,95 раза, можно добиться значительного увеличения прогрева скважины № 51 (рис. 2б);
- увеличение сухости пара, например в 1,2 раза, на скважине № 51 не приводит к существенному увеличению прогрева скважины (рис. 2в).

Эти выводы не противоречат здравому смыслу. Они не противоречат мнению опытных инженеров-нефтяников. Они лишь уточняют их знания на количественном уровне для конкретной скважины и конкретных условий проведения ПЦО.

Следует отметить, что полученные здесь практические выводы относятся только к конкретной скважине № 51 Усинского месторождения. Для других скважин этого месторождения требуется проведение аналогичных виртуальных экспериментов с помощью разработанной нейронной сети.

Для другого месторождения нейронная сеть непригодна. Она должна быть обучена заново на новых данных, собранных со скважин другого месторождения.

Для создания универсальной нейронной сети, пригодной для моделирования ПЦО на любой скважине любого месторождения, требуется добавление входных нейронов для ввода дополнительных данных, характеризующих особенности месторождения. Потребуется обучение нейронной сети на данных, собранных со многих месторождений.

Для удобства работы инженеров, занимающихся добычей нефти на скважинах Усинского месторождения, созданная нейронная сеть была снабжена пользовательским

Табл. 1. Условия проведения ПЦО и характеристики скважины № 51
Tab. 1. Conditions for carrying out the CSS and characteristics of well № 51

Входные параметры нейронной сети	Значения
Глубина до отметки по стволу, м	от 1 250 до 1 367
Перфорация	0 либо 1
Глубина скважины, м	1 457,7
Глубина до пакера, м	1 130
Длина паропровода, м	900
Зона залежи	1
Дата проведения ГИС, месяц	11
Расход пара на ПГУ по счетчику, т/ч	320
Давление пара на ПГУ, атм.	89
Температура пара на ПГУ, °С	302
Сухость пара на ПГУ, %	62
Объем закачанного пара на момент ГИС, т	5 488
Показания счетчика расхода пара на устье, т/ч	5,7
Давление пара на устье, атм.	77
Температура на устье, °С	268
Дата начала закачки пара, месяц	10
Количество скважин, запитанных на ПГУ, шт.	2
День проведения ГИС с начала закачки пара	25
Глубина от уровня моря до отметки, м	от 1 122 до 1 227,2
Расход пара на ПГУ на одну скважину, т/сут	160

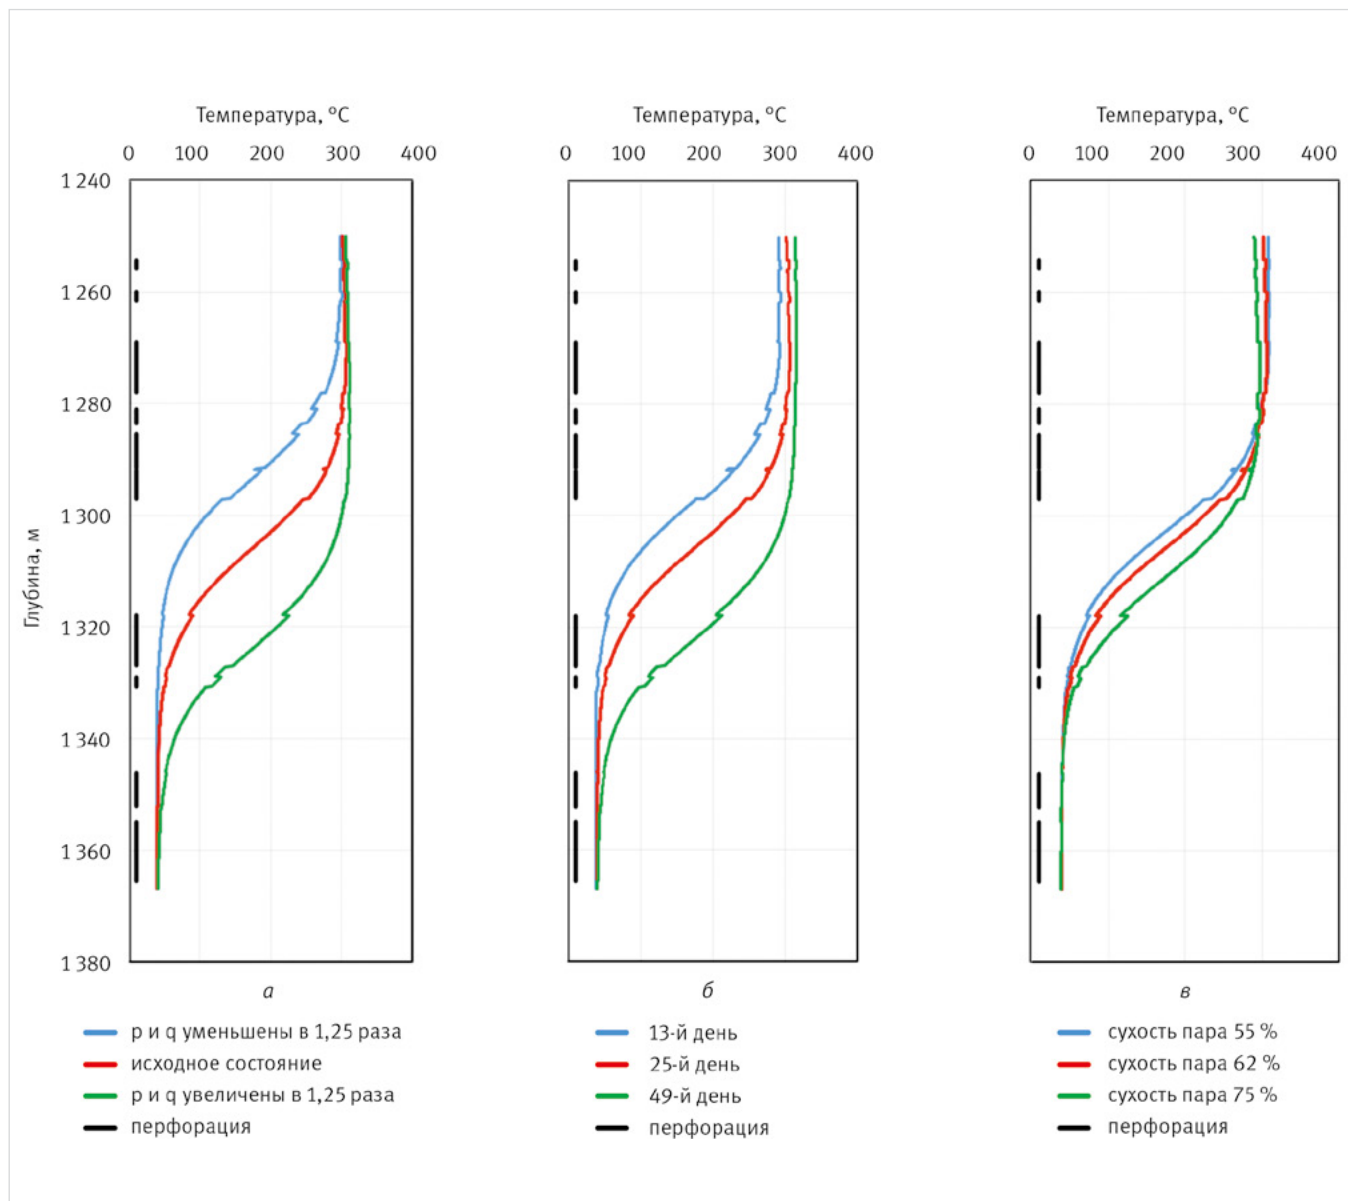


Рис. 2. Результаты виртуальных компьютерных экспериментов:
 а – влияние давления пара (p) и расхода пара (q);
 б – влияние продолжительности цикла ПЦО и объема закачанного пара;
 в – влияние сухости пара на парогенераторной установке
 Fig. 2. Results of virtual computer experiments:
 а – effect of steam pressure (p) and steam flow rate (q);
 б – the effect of the duration of the CSS cycle and the volume of injected steam;
 в – effect of steam dryness in a steam generator plan

интерфейсом. Получившийся в результате этого инженерный программный продукт получил название «Калькулятор ПЦО» и был запатентован [9]. «Калькулятор ПЦО» запускается по ссылке: <http://77.91.69.125/rcoCalc.html>.

Выводы

Подтверждена довольно неочевидная гипотеза о том, что сведений о параметрах пара, измеренных на уровне устья, а также информации о времени года и общих характеристиках скважины достаточно для прогнозирования температуры на любой глубине скважины. Создан инженерный программный продукт, позволяющий частично или полностью отказаться от применения трудоемкой и ненадежной технологии геофизических исследований скважин путем спуска в скважину прибора ГИС. С помощью разработанного программного продукта можно прогнозировать распределение температуры по стволу

скважины, проводить виртуальные компьютерные эксперименты, меняя входные параметры, получать ответ на вопрос «каким будет распределение температуры в скважине, если поменять тот или иной параметр ПЦО?». Это позволяет инженерам детально исследовать различные сценарии проведения процесса ПЦО. Инженеры, пользуясь разработанным программным продуктом, могут находить и реализовывать рациональные режимы ПЦО, минимизировать риски, достигать экономической рентабельности комплексных проектов по добыче нефти.

Литература

1. Hasanvand M., Berneti S.M. Predicting oil flow rate due to multiphase flow meter by using an artificial neural network. Energy Sources, Part A: Recovery, utilization and environmental effects, 2015, Vol. 37, issue 8, P. 840–845. (In Eng).
2. Bhattacharya S., Ghahfarokhi P.K., Carr T.R.,

- Pantaleone S. Application of predictive data analytics to model daily hydrocarbon production using petrophysical, geomechanical, fiber-optic, completions, and surface data: A case study from the Marcellus Shale, North America. Journal of petroleum science and engineering, 2019, issue 176, P. 702–715. (In Eng).
3. George A. Predicting oil production flow rate using artificial neural networks – the volvo field case. society of petroleum engineers. SPE Nigeria Annual International Conference and Exhibition, 2021, August 2–4, SPE-208258-MS. (In Eng).
4. Baki S., Dursun S. Flowing bottomhole pressure prediction with machine learning algorithms for horizontal wells. SPE Annual Technical Conference and Exhibition, Houston, Texas, USA, October 2022, SPE-210235-MS. (In Eng).
5. Ng C.S.W., Jahanbani Ghahfarokhi A., Nait Amar M. Well production forecast

- involve field: application of rigorous machine learning techniques and metaheuristic algorithm. Journal of petroleum science and engineering, 2022, issue 208, 109468, 14 p. (In Eng).
6. Yasnitsky L.N. Algorithm for searching and analysing abnormal observations of statistical information based on the Arnold – Kolmogorov – Hecht-Nielsen theorem. International journal of advanced trends in computer science and engineering, 2020, Vol. 9, issue 2, P. 1814–1819. (In Eng).
7. Ясницкий Л.Н. Развитие научной школы искусственного интеллекта в пермских университетах: история и научный приоритет (обзорная статья). Прикладная математика и вопросы управления. 2018. № 4. С. 99–130.
8. Черепанов Ф.М., Ясницкий Л.Н. Нейросимулятор 5.0: Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г.
9. Алексеев И.Б., Степанов В.А., Ясницкий Л.Н. Инженерный программный продукт «Калькулятор ПЦО»: Свидетельство Роспатент о государственной регистрации программы для ЭВМ № 2022682778 от 25.11.2022 г.

ENGLISH

Results

Interesting practical conclusions follow from the results of virtual computer experiments presented in the previous section:

- by increasing the pressure and flow rate of injected steam, for example, by 1,25 times, a significant increase in well heating can be achieved in well № 51;
- by increasing the duration of the CSS process, for example, by 1,95 times, it is possible to achieve a significant increase in the heating of well № 51;
- an increase in steam dryness, for example, by 1,2 times, in well № 51 does not lead to a significant increase in well heating.

These conclusions do not contradict common sense. They do not contradict the opinion of experienced petroleum engineers. They only clarify their knowledge on a quantitative level for a particular well and specific conditions for conducting CSS.

It should be noted that the practical conclusions obtained here apply only to a specific well № 51 of the Usinskoye field. For other wells of this field, similar virtual experiments are required using the developed neural network.

For another field, the neural network is unsuitable. It must be retrained on new data collected from wells in another field.

To create a universal neural network suitable for modeling CSS at any well of any field, it will be necessary to add input neurons to enter additional data characterizing the features of the field. It will be necessary to train a

neural network on data collected from many fields.

For the convenience of engineers involved in oil production at the wells of the Usinskoye field, the created neural network was equipped with a user interface. The resulting engineering software product was named “CSS Calculator” and was patented. “CSS Calculator” is launched at the link: <http://77.91.69.125/pcoCalc.html>.

Conclusions

A rather non-obvious hypothesis was confirmed that information about the steam parameters measured at the wellhead level, as well as information about the time of year and the general characteristics of the well, is sufficient to predict the temperature at any depth of the well. An engineering software product has been created that makes it possible to partially or completely abandon the use of time-consuming and unreliable technology for geophysical well surveys by lowering a well logging tool into the well. Using the developed software product, it is possible to predict the temperature distribution along the wellbore, conduct virtual computer experiments by changing the input parameters, and get an answer to the question «what will be the temperature distribution in the well if one or another CSS parameter is changed?». This allows engineers to explore in detail various scenarios for conducting the CSS process. Engineers, using the developed software product, can find and implement rational modes of CSS, minimize risks, and achieve economic profitability of complex oil production projects.

References

1. Hasanvand M., Berneti S.M. Predicting oil flow rate due to multiphase flow meter by using an artificial neural network. Energy Sources, Part A: Recovery, utilization and environmental effects, 2015, Vol. 37, issue 8, P. 840–845. (In Eng).
2. Bhattacharya S., Ghahfarokhi P.K., Carr T.R., Pantaleone S. Application of predictive data analytics to model daily hydrocarbon production using petrophysical, geomechanical, fiber-optic, completions, and surface data: A case study from the Marcellus Shale, North America. Journal of petroleum science and engineering, 2019, issue 176, P. 702–715. (In Eng).
3. George A. Predicting oil production flow rate using artificial neural networks – the involve field case. Society of petroleum engineers. SPE Nigeria Annual International Conference and Exhibition, 2021, August 2–4, SPE-208258-MS. (In Eng).
4. Baki S., Dursun S. Flowing bottomhole pressure prediction with machine learning algorithms for horizontal wells. SPE Annual Technical Conference and Exhibition, Houston, Texas, USA, October 2022, SPE-210235-MS. (In Eng).
5. Ng C.S.W., Jahanbani Ghahfarokhi A., Nait Amar M. Well production forecast in involve field: application of rigorous machine learning techniques and metaheuristic algorithm. Journal of petroleum science and engineering, 2022, issue 208, 109468, 14 p. (In Eng).
6. Yasnitsky L.N. Algorithm for searching and analysing abnormal observations of statistical information based on the Arnold – Kolmogorov – Hecht-Nielsen theorem. International journal of advanced trends in computer science and engineering, 2020, Vol. 9, issue 2, P. 1814–1819. (In Eng).
7. Yasnitsky L.N. Artificial intelligence in Perm universities: history and scientific priority (review article). Applied mathematics and control, 2018, issue 4, P. 99–130. (In Russ).
8. Cherepanov F.M., Yasnitsky L.N. Neurostimulator 5.0: Certificate of Rospatent on state registration of a computer program № 2014618208 dated 12.07.2014. (In Russ).
9. Alekseev I.B., Stepanov V.A., Yasnitsky L.N. Engineering software product “Calculator PCO”: Certificate of Rospatent on state registration of a computer program № 2022682778 dated 25.11.2022. (In Russ).

ИНФОРМАЦИЯ ОБ АВТОРАХ | INFORMATION ABOUT THE AUTHORS

Степанов Владимир Анатольевич, генеральный директор ООО «Нейрософт Глобал», Пермь, Россия
Для контактов: office@neurosoft-global.ru

Ясницкий Леонид Нахимович, профессор, директор по науке и инновациям, ООО «Нейрософт Глобал», Пермь, Россия

Stepanov Vladimir Anatolyevich, ceo, “Neurosoft Global” LLC Perm, Russia
Corresponding author: office@neurosoft-global.ru

Yasnitsky Leonid Nakhimovich, cdo, professor, “Neurosoft Global” LLC, Perm, Russia