

УДК 004.021

DOI: 10.22213/2410-9304-2021-3-55-64

Применение алгоритмов машинного обучения для решения задач нефтегазовой сферы

К. Н. Майоров, аспирант, ИжГТУ имени М. Т. Калашникова; ЗАО «ИННЦ», Ижевск, Россия

В статье рассматривается жизненный цикл разработки месторождения, проводится анализ процессов этапа проектирования разработки месторождений на предмет применения методов машинного обучения. Для каждого процесса выделены актуальные задачи, существующие решения на базе методов машинного обучения, предложены идеи и задачи, которые могли бы быть эффективно решены методами машинного обучения. По основной части процессов кратко описаны примеры решений, определены преимущества и недостатки подходов. Наиболее распространенным методом решения являются нейронные сети прямого распространения. При условии предварительной нормализации входных данных это наиболее универсальный алгоритм для задач регрессии и классификации. Однако в задаче подбора скважин на гидроразрыв пласта использовался целый ансамбль моделей машинного обучения, где помимо нейронной сети были случайный лес, градиентный бустинг и линейная регрессия. Для задачи оптимизации размещения сетки нефтедобывающих скважин определены недостатки существующих решений на базе нейронной сети и простого подхода обучения с подкреплением на основе Марковского процесса принятия решений. Предложен алгоритм глубокого обучения с подкреплением Alpha Zero, который ранее показал значительные результаты в роли искусственного интеллекта для игр. Этот алгоритм представляет собой поиск по дереву решений, который направляет нейронную сеть: более глубоко рассматриваются только те ветви, которые получили наилучшие оценки от нейронной сети. В статье освещены общие черты между задачами, для которых ранее применялась Alpha Zero, и задачей оптимизации размещения сетки нефтедобывающих скважин. Сделаны выводы о возможности использования и модификации алгоритма решаемой задачи оптимизации, предложен подход учета симметричных состояний в дереве Монте-Карло для сокращения числа требуемых симуляций.

Ключевые слова: машинное обучение, нейронные сети, задачи нефтегазовой сферы, прогноз добычи нефти, оптимизация размещения сетки скважин, глубокое обучение с подкреплением, дерево Монте-Карло, Alpha Zero.

Введение

Технологии машинного обучения очень активно начинают применяться для решения задач в нефтегазовой сфере. И хотя в таких системах довольно сложно интерпретировать принятые ими решения, в отличие от математических моделей и экспертных систем, они более просты в реализации и практически не имеют ограничений при увеличении сложности моделирования. На первый взгляд, это высказывание может показаться сомнительным: как внедрение машинного обучения может сделать разработку проще, а не усложнить и без того сложную систему? Причина в том, что машинное обучение позволяет получить желаемый результат без каких-либо знаний о математической модели анализируемого процесса – алгоритмы могут быть унифицированы под любую сферу применения. Кроме того, основные алгоритмы машинного обучения уже реализованы в программных модулях в таких языках программирования, как Python и R.

Целью данной статьи является проведение анализа процессов проектирования разработки месторождений на предмет применения методов машинного обучения, а также предложение новых идей и задач, которые могли бы быть эффективно решены методами машинного обучения.

Статья построена следующим образом: вначале представлена таблица с задачами рассматриваемых процессов, существующими решениями на базе машинного обучения и идеями, предлагаемыми автором, затем большая часть примеров рассматривается подробно в рамках каждого процесса.

Процессы проектирования разработки месторождения

Жизненный цикл разработки месторождений нефти или газа делится на множество этапов (рис. 1): от поиска месторождений до транспортировки ресурса.



Рис. 1. Структура процессов в области проектирования разработки месторождения
 Fig. 1. The structure of processes in the field of field development design

Рассмотрим поподробнее процессы этапа проектирования разработки месторождений и составим таблицу, содержащую задачи каж-

дого такого процесса, существующие их решения на базе машинного обучения (ML-Machine Learning) и возможные новые решения.

Задачи процессов проектирования разработки месторождения и ML- решения Objectives of field development design processes and ML-solutions

Процесс	Задачи	Существующие ML-решения	Предлагаемые автором ML-решения
Моделирование ГМ (геологические модели), ГДМ (гидродинамические модели)	Построение прокси-моделей для ГДМ	1. Нейронный оператор Фурье, аппроксимирующий дифференциальные уравнения параметров ГДМ [1] 2. Аппроксимация дифференциальных уравнений ГД-процессов нейронными сетями [2]	Нет
Анализ выработки запасов	– Построение карт остаточных запасов – Статистика выработки запасов	Нет	Кластеризация зон по остаточным запасам
Анализ базовой добычи	– Анализ эффективности проведенных ГТМ (геолого-технических мероприятий) – Сбор статистики скважин по темпам падения, добычи – Классификация скважин на низкодебитные и высокодебитные – Исследование интерференции скважин	Оценка интерференции скважин полносвязной нейронной сетью	Кластеризация скважин по темпам падения, добыче
Анализ системы ППД	– Построение карт пластового давления – Статистика работы нагнетательных скважин	Построение карт изолиний с помощью нейронных сетей	Выделение зон с пониженным давлением методами кластеризации
Анализ фонда скважин	Построение таблиц по фондам скважин	Нет	Нет
Обоснование системы разработки	– Нахождение оптимальной схемы размещения скважин (регулярная+нерегулярная) – Техничко-экономическое обоснование КИНа (коэффициента извлечения нефти)	Разработка алгоритма оптимизации процесса эксплуатации нефтяного месторождения Каймысовского свода на основе метода обучения с подкреплением	Размещение нерегулярной сетки скважин с помощью алгоритма Alpha Zero

Окончание таблицы

Процесс	Задачи	Существующие ML-решения	Предлагаемые автором ML-решения
Рейтинг бурения скважин	Определение последовательности бурения скважин	Разработка алгоритма оптимизации процесса эксплуатации нефтяного месторождения Каймысовского свода на основе метода обучения с подкреплением	Выбор оптимальной последовательности бурения скважин с помощью алгоритма Alpha Zero
Подбор и анализ ГТМ	Оценка эффективности ГТМ (поиск скважин кандидатов на проведение ГТМ и анализ эффективности)	1. Оценка эффективности обработок призабойных зон нефтяных скважин (Деревья решений) 2. Комплексная методика прогноза эффективности геолого-технических мероприятий на основе алгоритмов машинного обучения 3. Подбор скважин-кандидатов для проведения гидроразрыва пласта на основе математического моделирования с использованием методов машинного обучения	Нет
Расчет уровней добычи	– Прогноз дебитов – Прогноз суммарной (годовой) добычи за период	Прогноз дебитов и суммарной добычи нейронными сетями прямого распространения	Нет
Анализ инфраструктуры	Прогноз отказоустойчивости насосного оборудования и трубопроводов, газовых турбин	1. Оценка срока полезной эксплуатации трубопроводов нейронными сетями 2. Оптимизация технического обслуживания газовых турбин с помощью алгоритма глубокого обучения с подкреплением SARSA	Нет
Подготовка ПТД	Оформление проектно-технического документа	Нет	Генерация текста отчетов нейронной сетью архитектуры LSTM

В [3] освещены результаты применения нейронных сетей прямого распространения в задачах процессов анализа базовой добычи, расчета уровней добычи и поддержки пластового давления. Далее рассмотрим процессы поподробнее.

Анализ базовой добычи

Для процесса анализа базовой добычи машинное обучение применяется только в задаче оценки степени взаимодействия (интерференции) скважин. Для оценки интерференции обычно применяются методы численного моделирования пласта с коэффициентами взаимовлияния скважин. Данная задача является задачей регрессии по прогнозу добычи при взаимо-

действию двух или более скважин. В качестве входных признаков могут быть использованы параметры сразу нескольких типов скважин: добывающих и нагнетательных. Изменяя эти параметры, можно увидеть, как меняется итоговая добыча. В рассматриваемой обучающей выборке входными параметрами являются приемистость нагнетательных скважин, дебиты по воде и нефти для добывающих скважин, а также время работы и текущее время. На рис. 2 представлена оценка нейронной сети степени взаимодействия между низкодебитной добывающей скважиной 1029 и нагнетательной скважиной 2026. По оси абсцисс указаны зна-

чения приемистости нагнетательной скважины. По оси ординат значения соответствуют реакции добывающей скважины 1029. Значение приемистости, равное нулю, соответствует ре-

альному значению приемистости скважины в выбранный промежуток времени, – 100 соответствует полному отключению скважины, а 100 – двукратному увеличению закачки.

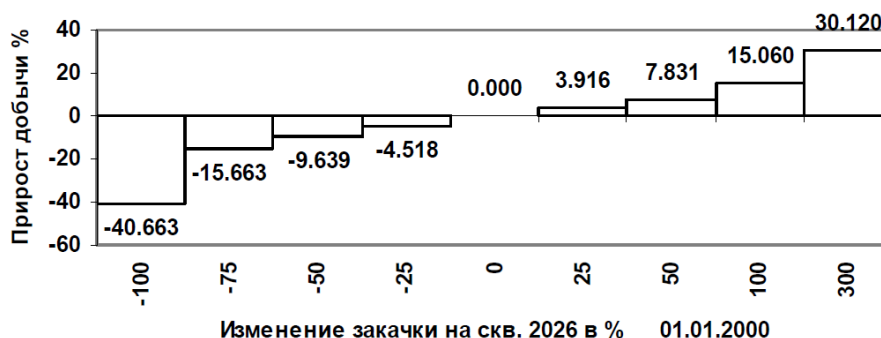


Рис. 2. Оценка нейронной сети интерференции скважин 1029 и 2026
Fig. 2. Evaluation of the interference neural network of wells 1029 and 2026

Актуальной задачей для применения машинного обучения для процесса анализа базовой добычи может быть кластеризация зон размещения скважин по темпам падения и добыче.

Расчет уровней добычи

Прогноз дебитов и суммарной добычи – основные задачи процесса расчета уровней добычи. Рассмотрим результаты с применением линейной сети, простого многослойного перцептрона с одним скрытым слоем, состоящим из 2 нейронов и сигмоидальной функцией активации для выходного нейрона и сетей архитектур RBFN (сеть радиально-базисных функций) и GRNN (обобщенно-регрессионной). В качестве входных данных для нейронной сети ис-

пользуются данные о пластовых и забойных давлениях, глубинах погружения насосов, динамическом уровне, технологических характеристиках оборудования, геологических характеристиках пласта. Выходным параметром является суточный дебит отдельной добывающей скважины. В данном примере нейронная сеть прогнозирует добычу для каждой скважины по отдельности и затем уже сопоставляются суммарные значения. На рис. 3 можно увидеть, насколько расходятся прогнозируемые значения суммарной добычи нефти от реальных значений при использовании различных архитектур нейронных сетей.




Рис. 3. Прогноз суммарной добычи для системы из 15 добывающих скважин и 6 нагнетательных с использованием сетей различной архитектуры

Fig. 3. Forecast of total production for a system of 15 production wells and 6 injection wells using networks of different architecture

Анализ поддержки пластового давления

Задача картопостроения является частью процесса анализа поддержки пластового давления и считается довольно обширной ввиду того, что при моделировании месторождения строится большое число различных карт: структурные карты кровли и подошвы коллектора, карты пористости, проницаемости, водонасыщенности и др. Обычно данная задача решается методами сплайн-интерполяции. Рассмотрим сравнение N-мерной сплайн-интерполяции и прогнозов нейронной сети для построения карт изолиний. На единичном квадрате наносится 80 нерегулярно расположенных интерполяционных узлов и в них рас-

считываются значения искомой функции. В качестве обучающего датасета для нейронной сети подаются координаты узлов интерполяции, а выходными параметрами являются рассчитанные значения функции. Для прогнозов берутся координаты узлов, рассчитанные на регулярной сетке. На рис. 4 показаны результаты расчетов. Тонкие линии построены с помощью прогнозов нейронной сети, а толстые – сплайн-методом. Видно, что результаты довольно близки. А это значит, что нейронные сети при правильном подборе архитектуры и гиперпараметров могут стать серьезной альтернативой в решении задачи построения карт.




Рис. 4. Карта изолиний, построенная методом сплайн-интерполяции и нейронной сети

Fig. 4. Contour map constructed by spline interpolation and neural network

Актуальной задачей для применения машинного обучения для процесса анализа поддержки пластового давления может быть выделение зон с пониженным давлением методами кластеризации.

Анализ эффективности ГТМ

Эффективность проводимых и планируемых ГТМ обычно оценивается сравнением базовых показателей с фактическими. Под базовыми показателями понимают показатели, которые могут быть получены при разработке месторождения изначальным методом – до проведения ГТМ. Наиболее распространенными способами для расчета базовых показателей добычи явля-

ются характеристики вытеснения (интегральные модели) и кривые падения (дифференциальные модели). При нейросетевом подходе данная задача, по сути, сводится к рассмотренной ранее регрессионной задаче прогноза суммарной добычи нефти. При этом в обучающую выборку добавляются параметры проводимых ГТМ, например, глубина погружений насосов. Важное преимущество подхода – это возможность прогноза базового уровня добычи не только для нескольких скважин, но и по отдельности.

В работе [4] рассматривается бинарная классификация результата проведения ГРП

(гидро разрыва пласта) на скважинах. Таким образом, выбираются наилучшие кандидаты для проведения ГТП. Для определения успешности рассчитывается разница между фактическим дебитом нефти и прогнозным вариантом после проведения ГТП – если разница выше заданного порога, то признак успешности равен единице, иначе – нулю. Прогнозный дебит нефти рассчитывается по следующей формуле:

$$Q_H = Q_{Ж} \cdot (1 - W), \quad (1)$$

где Q_H – дебит нефти; $Q_{Ж}$ – прогнозный дебит жидкости; W – прогнозная обводненность (д. е.)

Авторы использовали не только нейронные сети, но и другие модели машинного обучения, такие как линейная регрессия, случайный лес и градиентный бустинг (рис. 5).



Рис. 5. Входные данные, используемые модели и выходные параметры
Fig. 5. Input data, used models and output parameters

Анализ инфраструктуры

В области дефектологии и оценивания отказоустойчивости оборудования были релевантные исследования по оценке срока полезной эксплуатации трубопроводов [5]. На рис. 6 представлена примерная архитектура использовавшейся сети.



Рис. 6. Архитектура нейронной сети для оценки остаточного ресурса эксплуатации трубопровода
Fig. 6. Architecture of a neural network for assessing the residual life of the pipeline

В качестве входных данных использовались материал трубы, состояние, длина и скорость разрушения трубопровода.

В работе [6] рассматривается решение проблемы оптимизации технического обслуживания газовых турбин с помощью алгоритма глубокого обучения с подкреплением SARSA. Управление техническим обслуживанием газовых турбин заключается в принятии решений относительно как извлекаемых деталей, так и деталей, устанавливаемых на их место. На рис. 7 изображена общая схема работы системы обслуживания. Полагая, что на предприятии G газовых турбин каждая g -я турбина проходит обслуживание в разный момент времени t_0 , но с одинаковой периодичностью H . Для турбин рассчитано определенное предельное число циклов использования MNRC, которое может изменяться от 1 до R .

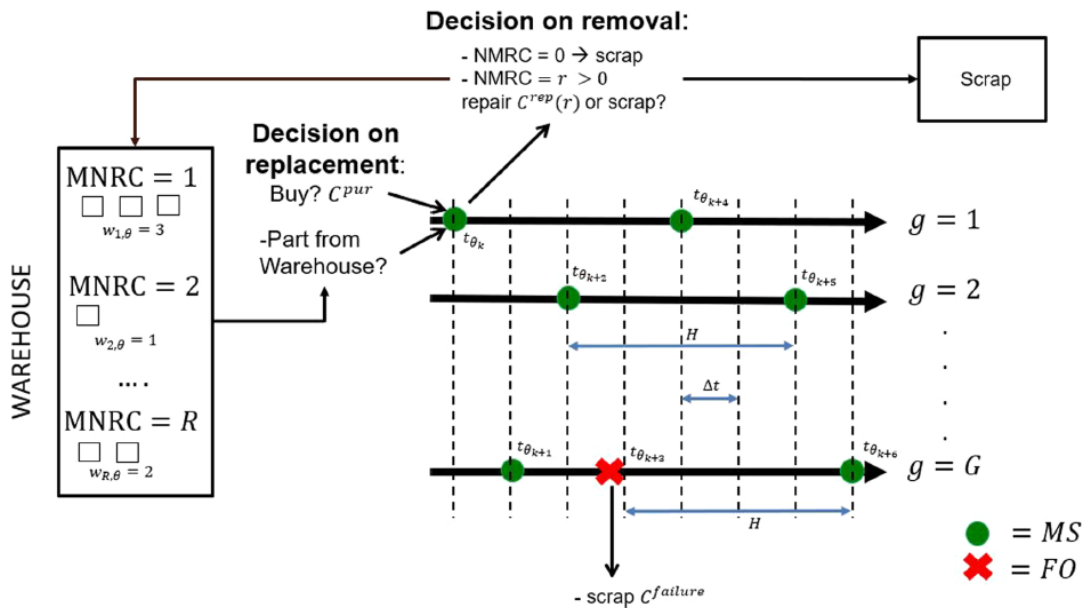


Рис. 7. Общая схема работы системы обслуживания газовых турбин. MS-плановое обслуживание турбины, FO-внеплановая остановка из-за повреждения

Fig. 7. General scheme of operation of the gas turbine service system. MS-scheduled turbine maintenance, FO-unscheduled shutdown due to damage

Обоснование системы разработки и рейтинг бурения скважин

Оптимизация размещения сетки скважин – сложная задача, которая захватывает сразу два процесса проектирования. Бурение новой скважины – крайне дорогое мероприятие, поэтому все предлагаемые системы разработки должны быть обоснованы убедительными показателями КИНа и NPV. Типичными способами решения задачи можно считать симплекс-методы, методы перебора, градиентные методы и др. [7, 8]. Были проведены значимые эксперименты и с применением нейронных сетей,

например, в работе [9] нейронная сеть прогнозирует суммарную добычу для всех возможных ячеек месторождения и затем они устанавливаются в местах с максимальными показателями. В работе [10] представлен подход обучения с подкреплением – динамического программирования на базе марковских процессов принятия решений. Цепь Маркова для последовательности бурения скважин представлена на рис. 8. Агент совершает какие-то действия (бурит новую скважину) и получает награду, эквивалентную дебиту нефти.




Рис. 8. Цепь Маркова для последовательности бурения скважин
Fig. 8. Markov chain for drilling sequence

Эти подходы не лишены существенных недостатков – полный перебор вариантов размещения потребует гигантского числа расчетов – и слабо учитывают историю размещений каждой скважины.

В 2018 году компания DeepMind представила алгоритм Alpha Zero (рассматривается в статье автора в данном журнале за 2019 год), который произвел революцию в сфере игрового искусственного интеллекта, победив чемпионов мира по шахматам, Го и другим играм. Алгоритм представляет собой поиск по дереву решений. Однако в глубину рассматриваются только ветви, получившие наиболее хорошие оценки [11]. А вот эти оценки выставляет уже нейронная сеть.

Выделим общие черты рассматриваемой задачи оптимизации размещения скважин и задач, где применялся Alpha Zero [12, 13]:

- большое пространство решений, перебрать полностью которое вычислительно трудно;
- важен конечный результат, а не на текущий момент – NPV на конец срока разработки месторождения;
- история предыдущих действий играет серьезную роль для принятия решений.

Полагаясь на вышеописанные сходства, можно предположить, что алгоритм Alpha Zero сможет также эффективно себя проявить в задаче оптимизации нерегулярной сетки скважин.

В Alpha Zero выбор действия на каждом ходу происходит после проведения ряда симуляций, раскрывающих дерево Монте-Карло. Для ускорения расчетов и уменьшения числа требуемых симуляций предлагается добавить учет симметричных состояний. Это может быть осуществлено внесением дополнительного компонента в функцию UCT (upper confidence bound for trees):

$$UCT = Q + cP \frac{\sqrt{N} + G}{1 + n}, \quad (2)$$

где Q – ожидаемая оценка узла, усредненная по всем визитам по ветви узла (0 – если ветка не исследована); P – априорная вероятность для действия в отношении этого узла (желательность). К ней может быть добавлен искусственный шум с помощью распределения Дирихле, для увеличения шансов улучшения оценки малоисследованной ветки. N – Сумма всех визитов узла родителя; n – число визитов к этой ветке; c – уровень исследования, балансирующий exploration vs exploitation, высокое значение c дает предпочтение менее исследованным

узлам; G – показатель приоритетности действия.

Показатель приоритетности действий обновляется после каждой симуляции. После анализа узла-листа нейронной сетью в случае отрицательной оценки действия для ветвей, которые относятся к симметричным действиям, устанавливается показатель приоритетности проверки этих ветвей, обратный оценке нейронной сети. При раскрытии ветви с показателем G , большим нуля, G обнуляется.

Подготовка ПТД

Заключительным этапом проектирования разработки является создание проектно-технического документа (ПТД). Этот документ содержит статистическую информацию, собранную на всех предыдущих этапах, а также текстовое описание результатов. На данный момент в этом процессе никак не задействованы алгоритмы машинного обучения. Однако можно предложить создание системы для автоматической генерации текста отчета с помощью рекуррентных нейронных сетей.

Выводы

Таким образом, в статье проведен анализ применения методов машинного обучения в решении задач проектирования разработки месторождений, оценены достоинства и недостатки алгоритмов и определены перспективы дальнейшего изучения и применения. Выдвинуто предположение о возможности применения алгоритма обучения с подкреплением Alpha Zero для решения задач оптимизации, в частности для задачи оптимального размещения сетки скважин.

Библиографические ссылки

1. Li Z. et al. Fourier neural operator for parametric partial differential equations // arXiv preprint arXiv:2010.08895. – 2020.
2. Valyuhov S., Kretinin A., Burakov A. Neural network modeling of hydrodynamics processes // Hydrodynamics-Optimizing Methods and Tools. 2011. P. 201-222.
3. Нейросетевое имитационное моделирование нефтяных месторождений и гидрогеологических объектов / Б. П. Иваненко и др. Томск : Издательский Дом ТГУ, 2014. 188 с.
4. Подбор скважин-кандидатов для проведения гидроразрыва пласта на основе математического моделирования с использованием методов машинного обучения / А. Ф. Азбуханов и др. // Нефтяное хозяйство. 2019. № 11. С. 38–42.
5. Артеева Т. Е., Земенков Ю. Д. Оценка срока полезной эксплуатации трубопроводов с использованием различных моделей искусственных нейронных сетей // Нефть. Газ. Новации. 2020. № 5. С. 72–74.

6. Compare M. et al. Reinforcement learning-based flow management of gas turbine parts under stochastic failures // *The International Journal of Advanced Manufacturing Technology*. 2018. Т. 99, № 9. С. 2981–2992.

7. Min B. H. et al. Optimal well placement based on artificial neural network incorporating the productivity potential // *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*. 2011. Т. 33, №. 18. С. 1726–1738.

8. Guerra N. Y. et al. Well Location Selection from Multiple Realisations of a Geomodel Using Productivity Potential Maps-A Heuristic Technique // *International Oil Conference and Exhibition in Mexico*. – Society of Petroleum Engineers, 2006.

9. Анализ неопределенностей при моделировании водогазового воздействия на нефтяной пласт с применением нейронных сетей / И. Н. Кошовкин и др. // *Известия Томского политехнического университета. Инжиниринг георесурсов*. 2010. Т. 316, № 1.

10. Гирич Н. А. Разработка алгоритма оптимизации процесса эксплуатации нефтяного месторождения Каймысовского свода на основе методов машинного обучения : магистерская диссертация. Томск, 2020. URL: <http://earchive.tpu.ru/handle/11683/62449>.

11. Božek P. et al. Information technology and pragmatic analysis // *Computing and informatics*. 2018. Т. 37, № 4. С. 1011–1036.

12. Silver D. et al. A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play // *Science*. 2018. Т. 362, № 6419. P. 1140–1144.

13. Pumperla M., Ferguson K. Deep learning and the game of Go // *Manning*. 2019. Т. 231. С. 279.

References

1. Li, Z., Kovachki, N., Azizzadenesheli, K., Liu, B., Bhattacharya, K., Stuart, A., & Anandkumar, A. Fourier neural operator for parametric partial differential equations, 2020, arXiv preprint arXiv:2010.08895.

2. Valyuhov, S., Kretinin, A., & Burakov, A. Neural network modeling of hydrodynamics processes. *Hydrodynamics-Optimizing Methods and Tools*, 2011, pp. 201–222.

3. Ivanenko B.P. Neural network simulation of oil fields and hydrogeological objects, *Tomsk, Izdatel'skij Dom TGU*, 2014, 187p. (in Russ.).

4. Azbukhanov A.F., Kostrigin I.V., Bondarenko K.A., Semenova M.N., Sereda I.A., Yulmukhametov D.R. [Selection of wells for hydraulic fracturing based on mathematical modeling using machine learning methods]. *Oil Industry*. 2019. Vol. 11. Pp. 38–42. (in Russ.).

5. Arteeva T. E., Zemenkov Ju. D. [Estimation of the useful life of pipelines using various models of artificial neural networks]. *Neft'. Gaz. Novacii*. 2020. No. 5, pp. 72–74 (in Russ.).

6. Compare, M., Bellani, L., Cobelli, E., & Zio, E. Reinforcement learning-based flow management of gas turbine parts under stochastic failures. *The International Journal of Advanced Manufacturing Technology*, 2018, 99(9), 2981–2992.

7. Min, B. H., Park, C., Kang, J. M., Park, H. J., Jang, I. S. Optimal well placement based on artificial neural network incorporating the productivity potential. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 2020, 33(18), 1726–1738.

8. Guerra, N. Y., Narayanasamy, R. Well Location Selection from Multiple Realisations of a Geomodel Using Productivity Potential Maps-A Heuristic Technique. In *International Oil Conference and Exhibition in Mexico*. Society of Petroleum Engineers, 2006, Cancun, Mexico.

9. Koshovkin, I. N., Anur'ev, D. A., Dejezhenko, A. [Uncertainty analysis in modeling water-gas impact on an oil reservoir using neural networks]. *Izvestija Tomskogo politehnicheskogo universiteta. Inzhiniring georesursov*. 2010. Vol. 316 (in Russ.).

10. Girich N. A. [Development of an algorithm for optimizing the operation of an oil field in the Kaimysov vault based on machine learning methods], 2020, p. 115. Available at: <http://earchive.tpu.ru/handle/11683/62449> (in Russ.).

11. Božek, P., Lozhkin, A., Galajdová, A., Arkhipov, I., Maiorov, K. Information technology and pragmatic analysis. *Computing and informatics*. 2018. Vol. 37. No. 4. Pp. 1011–1036.

12. Silver, D., Hubert, T., Schrittwieser, J., Antonoglou, I., Lai, M., Guez, A., Hassabis, D. A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play. *Science*, 2018, Vol.362, No. 6419, pp. 1140–1144.

13. Pumperla M., Ferguson K. Deep learning and the game of Go. *Manning Publications Company*, 2019. Vol. 231. P. 279.

Application of Machine Learning Algorithms for Solving Problems in the Oil and Gas Sector

K. N. Maiorov, Post-graduate, Kalashnikov ISTU, ZAO «INNC», Izhevsk, Russia

The paper examines the life cycle of field development, analyzes the processes of the field development design stage for the application of machine learning methods. For each process, relevant problems are highlighted, existing solutions based on machine learning methods, ideas and problems are proposed that could be effectively solved by machine learning methods. For the main part of the processes, examples of solutions are briefly described; the advantages and disadvantages of the approaches are identified. The most common solution method is feed-forward neural networks. Subject to preliminary normalization of the input data, this is the most versatile algorithm for regression and classification problems. However, in the problem of selecting wells for hydraulic fracturing, a whole ensemble of machine learning models was used, where, in addition to a neural network, there was a random forest, gradient boosting and linear regression. For the problem of optimizing the placement of a grid of oil wells, the disadvantages of existing solutions based on a neural network and a simple reinforcement learning approach based on Markov decision-making process are identified. A deep reinforcement learning algorithm called Alpha Zero is proposed, which has previously shown significant results in the role of artificial intelligence for games. This algorithm is a decision tree search that directs the neural network: only those branches that have received the best estimates from the neural network are considered more thoroughly. The paper highlights the similarities between the tasks for which Alpha Zero was previously used, and the task of optimizing the placement of a grid of oil producing wells. Conclusions are made about the possibility of using and modifying the algorithm of the optimization problem being solved. An approach is proposed to take into account symmetric states in a Monte Carlo tree to reduce the number of required simulations.

Keywords: machine learning, neural networks, oil and gas problems, oil production forecast, well placement optimization, deep reinforcement learning, Monte Carlo tree, Alpha Zero

Получено: 27.05.2021