

УДК 622.276

КРИТИЧЕСКИЙ ОБЗОР ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ПРОГНОЗИРОВАНИЯ ПРОЦЕССОВ ПЕСКОПРОЯВЛЕНИЯ В НЕФТЕГАЗОВЫХ МЕСТОРОЖДЕНИЯХ

Албуркайба Амир Раад Рахим,

Аспирант

РГУ нефти и газа (НИУ) имени И.М. Губкина

Postgraduate student

ameerraad.ar97@gmail.com

Аннотация

В статье рассматривается пескопроявление представляет глобальную проблему для скважин, разрабатывающих песчаниковые коллекторы, вызывая снижение добычи вплоть до остановки скважин. Обзор посвящён использованию методов искусственного интеллекта (ИИ) для прогнозирования начала пескопроявления. Рассмотрены такие подходы, как искусственные нейронные сети, генетические алгоритмы, оптимизация роя частиц и метод опорных векторов.

Модели используют параметры, влияющие на пескопроявление: глубина, акустическое время, дебиты газа и воды, прочность пласта, забойные давления, критическая депрессия, напряжения пород, плотность перфорации и продолжительность беспесчаной добычи. Результаты представлены в форме прогнозов критического депрессионного давления или вероятности пескопроявления.

Ключевые слова: пескопроявление, прогнозирование, искусственный интеллект, искусственные нейронные сети, генетические алгоритмы, оптимизация роя частиц, песчаниковые коллекторы, модели прогнозирования.

CRITICAL REVIEW OF ARTIFICIAL INTELLIGENCE APPLICATIONS FOR PREDICTING SAND PRODUCTION IN OIL AND GAS FIELDS

Alburkaiba Ameer Raad Raheem,

Postgraduate student

Gubkin University

ameerraad.ar97@gmail.com

ABSTRACT

The article discusses sand production poses a global problem for wells producing from sandstone reservoirs, leading to a decrease in production rates and potentially causing well shutdowns. This review is dedicated to the use of artificial intelligence (AI) methods for predicting

the onset of sand production. Approaches such as artificial neural networks, genetic algorithms, particle swarm optimization, and support vector machines are considered.

The models employ parameters influencing sand production, including depth, acoustic travel time, gas and water flow rates, formation strength, bottomhole pressures, critical drawdown pressure, rock stresses, perforation density, and the duration of sand-free production. The results are presented in the form of predictions of critical drawdown pressure or the probability of sand production.

Keywords: Sand Production, Prediction, Artificial Intelligence, Artificial Neural Networks, Genetic Algorithms, Particle Swarm Optimization, Sandstone Reservoirs, Prediction Models.

Пескопроявление — это вынос песчаных частиц вместе с добываемыми флюидами при определенных условиях [1]. Пескопроявление начинается с утраты связности горной породы вокруг ствола скважины и перфораций, за которым следует перемещение разрушенных частиц породы с потоком жидкости и их поступление в ствол скважины, на устье и в поверхностное оборудование вместе с добываемыми флюидами [2]. Около 60% нефтяных и газовых скважин на Ближнем Востоке добывают из песчаниковых коллекторов, но эта доля увеличивается до 70%, если учитывать все месторождения в мире [3].

На основе полевых наблюдений пескопроявление классифицируется на три типа:

1- Преходящее пескопроявление: возникает из-за кислотных обработок, очистки после перфорации и прорыва воды; снижается со временем при тех же условиях добычи.

2- Постоянное пескопроявление: песок накапливается внутри ствола скважины и увеличивает глубину скопления. В зависимости от концентрации песка и подъемной способности потока жидкости, добывающий интервал может в конечном итоге быть заблокирован. Иногда оно продолжается в допустимых количествах в зависимости от эксплуатационных ограничений, связанных с эрозией, вместимостью сепараторов, отложениями песка, искусственным подъемом, местоположением скважины и т.д.

3- Катастрофическое высокое поступление песка: происходит при резком открытии или закрытии скважины; классифицируется на два сценария отказа: образование песчаной пробки, создающей мостик из песка в трубах или штуцерах при закрытии скважины, и массовый приток песка, заполняющий забой скважины [3].

Инженер по заканчиванию скважин должен знать условия, при которых возможно пескопроявление, перед применением любого метода контроля его проявления.

Поэтому решение о применении или неприменении методов контроля пескопроявления требует прогнозирования его начала.

Оптимальное управление пескопроявлением требует полного понимания факторов, вызывающих проблему песка, чтобы можно было разработать различные проверенные методы и инструменты для прогнозирования начала пескопроявления и его контроля [5].

Начало пескопроявления связано с добычей из слабых пластов, увеличением обводненности из хрупких до средне несцементированных коллекторов, падением давления в уплотненных твердых породах, высокими аномальными тектоническими силами вблизи прочных коллекторов, резким открытием или закрытием скважины для потока или высокой скоростью добычи [6], неподходящей плотностью перфорации, высокой проницаемостью, формой и геометрией перфорационных каналов, высокой вязкостью жидкости, значениями и изменениями напряжений *in situ*, изменением насыщенности флюидов, факторами прочности, представленными (прочностью материалов, внутренним трением частиц, песчаной аркой и капиллярными силами), а также некоторыми эксплуатационными параметрами, такими как стратегии

бурения/заканчивания. Разница температур между стволом скважины и пластом и коэффициент термической упругости также влияют на увеличение или снижение пескопроявления [7].

Исследования по прогнозированию пескопроявления начались с изучения устойчивости песчаных арок в лабораторном известном эксперименте "Trap-Door", предложенном Терцаги, но еще до этого [8] упоминал пескопроявление как одну из проблем, связанных с добычей из нецементированных пластов. С развитием нефтегазовой промышленности было представлено множество научных методов для прогнозирования пескопроявления, и самым современным методом является использование искусственного интеллекта.

Теория: за последние несколько десятилетий многие авторы потратили большое количество времени и усилий на идентификацию и разработку моделей для прогнозирования пескопроявления как функции напряжения в породе коллектора, пластового давления, скорости добычи, характеристик пласта и перепада давления, типа и свойств флюида и других факторов влияния. Эти модели поддерживают оптимизацию проектирования заканчивания скважин, а также полевые операции, включая контроль добычи и управление пескопроявлением [9]. Применение искусственного интеллекта (ИИ) в прогнозировании пескопроявления началось в конце прошлого века [9]. Искусственного интеллекта, использованный в рассматриваемой литературе, будет определен и обсужден в следующих разделах, с последующим описанием того, как его использовать и какие данные были применены в основных частях работы.

1. Искусственная нейронная сеть: искусственная нейронная сеть (ИНС) обрабатывает информационные системы с уникальными характеристиками производительности, и ее функция аналогична биологическим нейронным сетям [11]. Искусственная нейронная сеть классифицируется по связям между узлами, способу определения весов связей (алгоритмы обучения и тренировки) и функции активации. В работе [12] упомянул о первом исследовании по искусственной нейронной сети, представленно [13] в 1943 году в котором обсуждались различные приложения исчисления. Впоследствии в 1958 году изобрел перцептрон для разработки вектора весов, который разделяет классы, поэтому была разработана многослойная структура для преодоления ограничений простого перцептрона. Новая искусственная нейронная сеть под названием Adeline была разработана в [14].

Как показано ранее, применение искусственной нейронной сети в нефтегазовой промышленности примерно началось в последнем десятилетии двадцатого века.

В 2019 году в своем обзорном документе цитировали множество работ по истории искусственной нейронной сети и ее применению в нефтегазовой промышленности и представили [15] краткую блок-схему успешных шагов по применению искусственной нейронной сети в нефтяной и газовой промышленности, как показано на следующем рисунке 1:




Рисунок 1. Блок-схема успешного применения искусственной нейронной сети в шагах нефтяной и газовой промышленности.

Были рассмотрены многие типы искусственной нейронной сети, и далее будет объяснено, что для прогнозирования пескопроявления необходимо продемонстрировать:

Обобщённая регрессионная нейронная сеть (ОРНС) была введена для решения задачи разработки уникального уравнения для статистических разбросов точек из простого регрессионного анализа. Результаты Обобщённая регрессионная нейронная сеть

реализуются на основе функции плотности вероятности данных, а не предположительной функции. Она состоит из четырех слоев: входного слоя, образного слоя, суммирующего слоя с половиной узлов входного слоя и выходного слоя [16]. Обобщённая регрессионная нейронная сеть используется для оценки непрерывных переменных, как в стандартных методах регрессии, и на рисунке 2 показан пример структуры Обобщённая регрессионная нейронная сеть:

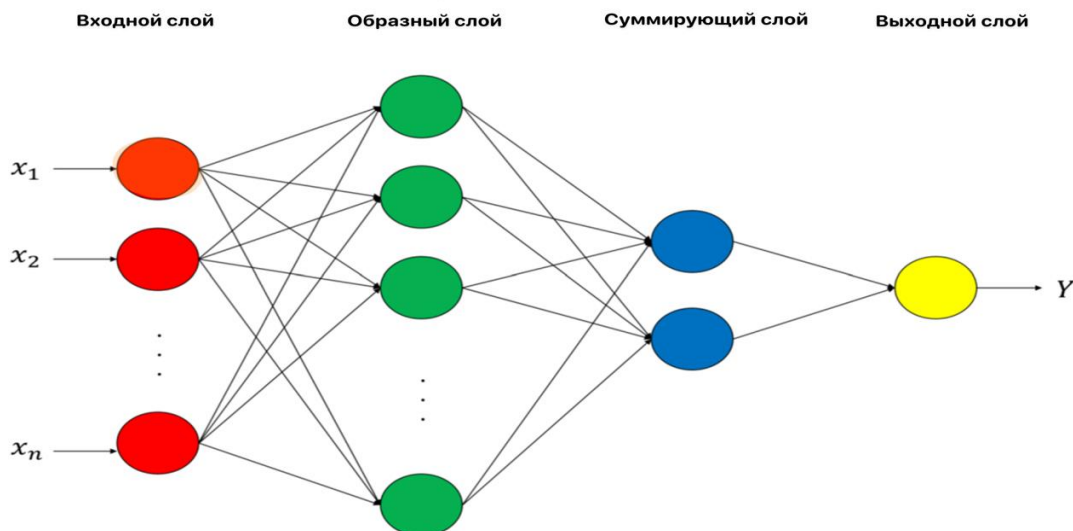


Рисунок 2. Пример структуры обобщённая регрессионная нейронная сеть.

Нейронные сети прямого распространения (НСПР) – это простой тип искусственной нейронной сети, в которой информация проходит в одном направлении к скрытым слоям и выходит из выходного слоя без каких-либо циклических петель [16].

Существует два типа Нейронные сети прямого распространения: однослойный перцептрон, состоящий из входного и выходного слоев, и многослойные сети с входным, скрытым и выходным слоями [17]. Обратное распространение – это обобщенный алгоритм наименьших средних квадратов для минимизации среднеквадратичной ошибки, который описывается как алгоритм обучения с учителем, применяемый к нелинейной многослойной структуре узлов прямого распространения. Обратное распространение направляет результаты двумя способами: прямое распространение, как показано выше, и обратная фаза, в которой вносятся изменения в веса связей на основе различий между вычисленными и ожидаемыми выходами. На рисунке 3 показан пример Нейронные сети прямого распространения с обратным распространением:




Рисунок 3. Пример Нейронные сети прямого распространения с обратным распространением.

2. Генетический алгоритм (ГА) — это стохастический метод решения и оптимизации ограниченных и свободных задач, основанный на случайных популяциях гауссовского случайного распределения. Множественные решения генетический алгоритм вдохновлены представлением хромосом индивидуумов. Каждая хромосома имеет набор переменных, которые симулируют гены [18]. Отбор первоначально основан на методе рулетки, который является одним из методов отбора, таких как метод Больцмана, турнирный, ранговый, стационарный, усечение, локальный, нечеткий, равномерный по приспособленности, линейный ранговый и стационарное воспроизведение. Блок-схема работы генетический алгоритм представлена на рисунке 4:



Рисунок 4. Блок-схема работы генетического алгоритма.

3. Алгоритм оптимизации роя частиц (ОРЧ) был представлен в 1995 году [19] как метод поиска на основе популяции для оптимизации непрерывных нелинейных функций. Каждая популяция называется роем с количеством частиц, которые могут иметь решение задачи и двигаться с определенной скоростью с возможностью корректировать свое положение относительно других частиц и опыта полета, пока не достигнут наилучшего положения (личного лучшего), которое будет использоваться в решении. На рисунке 5 показан пример оптимизации роя частиц:

Входной слой Скрытый слой Выходной слой




Рисунок 5. Пример оптимизации роя частиц.

4. Метод опорных векторов (МОВ) — это непараметрический двоичный линейный классификатор, использующий регрессионный анализ. Это алгоритм обучения с учителем для распознавания образов и анализа данных, который широко изучен как для классификации, так и для регрессионного анализа [20]. Метод наименьших квадратов опорных векторов метод опорных векторов был представлен в 1999 году как модификация метод опорных векторов для увеличения скорости на основе решения, полученного путем решения линейной системы уравнений вместо решения задачи квадратичного программирования, связанной со стандартным метод опорных векторов [21].

Применение методов искусственного интеллекта в прогнозировании пескопроявления

Многие авторы использовали вышеописанные методы искусственного интеллекта для прогнозирования пескопроявления. Первые искусственные нейронные сети для прогнозирования начала пескопроявления были созданы в 1999 году; они использовали два типа: топологии нейронные сети прямого распространения и искусственная нейронная сеть.

Данные использовались для прогнозирования начала пескопроявления, связанного с двадцатью тремя скважинами с проблемами песка и восемью газовыми скважинами без песка в Северном Адриатическом бассейне. Рассматриваемые влияющие факторы при построении искусственная нейронная сеть для проблемных скважин включали: общую вертикальную глубину, время прохождения акустического сигнала, дебиты газа и воды, когезионную прочность пласта, забойные давления при закрытии и притоке, депрессию, критическое депрессионное давление, эффективное вертикальное напряжение перекрывающих пород, длину интервала, плотность перфорации и продолжительность беспесчаной добычи в годах. Те же факторы для проблемных двадцати трех скважин учитывались в скважинах без песка, за исключением замены критического общего перепада давления общим перепадом давления в скважине, а период беспесчаной добычи скважины заменялся ее сроком службы в годах.

Перед построением двух искусственная нейронная сеть были предприняты следующие действия:

1. Оценка прочности горных пород на основе данных каротажа;
2. Анализ недооценки и переоценки скважин с проблемой песка;
3. Корреляция проблемы песка в терминах графика дебита газа с глубиной, который показал очень хаотичное и без явной систематической распределения;
4. Анализ дебита газа на перфорацию с глубиной, который привел к тем же выводам, что и предыдущий шаг;
5. Интерпретация отношений между графиком депрессии, дебитом газа и общим перепадом давления с глубиной, которые не показали прямой связи депрессии с потоком песчаных частиц и реального влияния обводненности на начало пескопроявления, несмотря на то, что предыдущие исследования заключали обратное;
6. Выделение трех зон песка (опасная, рискованная и свободная) на графике общего перепада давления в зависимости от глубины, а также корреляция прочности пород с критическим депрессионным давлением;

Результаты показали одну из четырех возможностей:

1. Булева классификация прогнозирования начала пескопроявления: 0 указывает на отсутствие проблемы песка.
2. Значение 1 указывает на существование проблемы песка.
3. Проблемный год, показывающий вероятный срок службы скважины без пескопроявления.
4. Потенциал пескопроявления для учета периодов времени проблемы песка, определения общего и критического депрессионного давления.

Использование двух искусственная нейронная сеть было направлено на учет влияния структуры сети и тестирования образцов.

Важность несвязанной прочности на сжатие для прогнозирования потенциального пескопроявления в реальном времени и расчета критического депрессионного давления была подчеркнута в 2013 году [22]. В 2010 году с использованием алгоритмов обучения с учителем нейронные сети прямого распространения на языке C++, учитывая механические свойства, такие как сжимаемость породы, свойства, приводящие к разрушению, как путь напряжения, петрофизические и текстурные свойства, такие как пористость, средний размер зерна и сортировка. Все полученные данные были разделены на три части для целей обучения, перекрестной проверки и тестирования искусственная нейронная сеть [23].

Данные были преобразованы в близкое к нормальному распределение из-за наличия выбросов и нелинейности, что улучшает работу искусственной нейронной сети и ускоряет ее [24]. Был проведен анализ чувствительности к многим влияющим параметрам на производительность искусственной нейронной сети; производительность увеличивалась с наименьшей ошибкой при увеличении скорости обучения до 0,75, увеличении числа нейронов в скрытых слоях и уменьшении числа скрытых слоев. В результате предсказанные значения несвязанная прочность на сжатие были сопоставлены с измеренными, что позволило определить глубины начала проблемы песка.

Сравнительное исследование по расчету с помощью двух моделей сдвигового разрушения, модели растягивающего разрушения и модели искусственной нейронной сети было выполнено в 2011 году Азадом и др. Основная цель заключалась в применении метода искусственной нейронной сети в этом исследовании. Выбранные данные были получены из трех нефтяных месторождений, расположенных на юге Ирана, добыча на которых ведется из трех пластов: Асмари, Илам и Сарвак, каждый из которых разделен соответственно на пять, три и семь подзон. Важные влияющие факторы прогнозирования пескопроявления были разделены на:

- 1.Свойства пласта и прочности;
- 2.Свойства пласта и добычи;
- 3.Характеристики заканчивания.

Первые два фактора были учтены в искусственной нейронной сети, а последний был проигнорирован. Была построена модель искусственной нейронной сети с одним скрытым слоем, принимая следующие данные во входной слой: параметры пласта (критическое депрессионное давление и пластовое давление), факторы пласта (перекрывающие и горизонтальные напряжения, критические глубины и время прохождения акустического сигнала). Источники входных параметров, таких как несвязанная прочность на сжатие, были рассчитаны из соответствующих эмпирических корреляций и образцов керна; другие данные получены из данных акустического каротажа сжатия и сдвига с учетом глубины перфорации и зон с высокой пористостью как источников начала пескопроявления. Набор из 38 данных был разделен на 24 для обучения, 7 для валидации и 7 для тестирования.

Обучающие наборы имели коэффициент корреляции 0,73 и использовались для нейронные сети прямого распространения, чтобы достичь тестового набора с коэффициентом корреляции 0,77. Результаты сравнения между четырьмя источниками критическое депрессионное давление показали, что искусственная нейронная сеть дала наилучшие результаты, что ожидаемо, поскольку искусственная нейронная сеть может преодолевать высокую сложность данных и предлагать подходящие решения по сравнению с тремя другими методами, которые требуют точных измерений и определения параметров механики горных пород; однако точность метода искусственной нейронной сети зависит от доступности точных данных во входном слое [25].

Те же данные, собранные из 23 скважин Северного Адриатического моря и изученные Канжем и Абу-Слейманом в 1999 году. Они построили модели множественной линейной регрессии, генетический алгоритм, развивающий множественной линейной регрессии, нейронные сети прямого распространения и оптимизации роя частиц для определения причинных параметров пескопроявления. Трехслойная искусственная нейронная сеть нейронные сети и прямого распространения с теми же переменными, использованными в искусственной нейронной сети, была построена как третий метод для прогнозирования критическое депрессионное давление с последовательностью чтения специфического ввода и обнаружения принадлежности к выходам: (1) если ошибка между выходными результатами и измеренными приемлема, то остановка; если нет, (2) нейронные сети прямого распространения будет использоваться для улучшения весов связей узлов искусственной нейронной сети. Аналогично, оптимизации роя частиц использовался для

непрерывной оптимизации нелинейных функций последнего нейронные сети прямого распространения. Результаты обоих методов показали повышение производительности нейронные сети прямого распространения с коэффициентом корреляции от 0,987 до 0,994 для оптимизации роя частиц в обучающем наборе, тогда как коэффициент корреляции нейронные сети прямого распространения равный 0,979 для оптимизации роя частиц равен 0,995 в тестовом наборе; таким образом, производительность оптимизации роя частиц лучше, чем нейронные сети прямого распространения, на всех этапах обучения и тестирования.

Различные подходы искусственного интеллекта, такие как методы опорных векторов и метод наименьших квадратов опорных векторов [26] для прогнозирования начала пескопроявления на основе тех же данных, полученных в работы [27]. Те же влияющие факторы предыдущих двух исследований использованы для этих двух методов. Разделение гиперплоскости во входном пространстве выполнено для построения опорных векторов в два шага: нелинейное отображение входных паттернов в пространство признаков более высокой размерности и построение разделяющей гиперплоскости с максимальным зазором. Выходы опорных векторов улучшены с помощью метод наименьших квадратов опорных векторов.

Результаты представлены как (1), что соответствует наблюдению песка, и (-1), что указывает на отсутствие песка. Качество классификации оценивалось с помощью матрицы ошибок в терминах: FP – количество ошибок, когда прогноз указывает на проблему песка, в то время как по полевым наблюдениям песка нет; FN – количество ошибок, когда прогноз указывает на отсутствие песка, в то время как по полевым наблюдениям есть проблема песка. Результаты прогнозирования пескопроявления относительно полевых наблюдений показали, что метод наименьших квадратов опорных векторов является мощным инструментом для прогнозирования пескопроявления, который дает точные результаты, помогая инженеру по проектированию заканчивая принимать решения о времени контроля песка и соответствующих инструментах.

Как обсуждалось в двух предыдущих исследованиях [10, 26], использовались одни и те же данные для прогнозирования начала пескопроявления; каждое исследование использовало свой подход, но цель была одна, с некоторыми отличиями. Все три исследования использовали одни и те же влияющие параметры для построения искусственная нейронная сеть.

Использовали нейронные сети прямого распространения и искусственная нейронная сеть для прогнозирования начала пескопроявления в терминах индикаторов песка: (1) – проблемный песок, (0) – отсутствие песка; установили простую связь между критическое депрессионное давление и когезионной прочностью, определили проблемный год, сделали вывод о потенциале песка, а также сравнили критическое депрессионное давление среди измеренных; полевое исследование итальянская генеральная нефтяная компания., в то время как последнее исследование [26] применило опорных векторов и метод наименьших квадратов опорных векторов для определения вероятности существования песка (1) или отсутствия песка (-1). На основе сравнений между этими тремя исследованиями и показали наилучшие результаты благодаря высокой точности, которая была идентична на 100% полевым наблюдениям, что показывает полный набор данных из исследования [27] с последней колонкой результатов метод наименьших квадратов опорных векторов.

На нефтяных и газовых месторождениях в районе дельты Нигера. Гипер-алгоритм симплекс-метода Нелдера-Мида с имитацией отжига использован для устранения недостатков, связанных с одиночной реализацией процедуры имитации отжига или алгоритма Нелдера-Мида, сочетая простую форму метода Нелдера-Мида и имитацию отжига. Многие прямые и косвенные влияющие параметры на начало пескопроявления

введены в систему: измеренная глубина, азимут, общий дебит нефти и газа, модель толстостенного цилиндра, количество выстрелов на фут, давление в середине перфорации, вязкости воды и газа, несвязанная прочность на сжатие, пористость, проницаемость, остаточные и связные насыщенности нефтью и водой, толщина перфорации, радиус ствола скважины, газовый фактор растворенной нефти, плотности нефти и газа, объемный коэффициент пласта нефти и воды. Предсказанные результаты были идентичны наблюдаемым полевым данным, что доказывает, что метод гипер-алгоритма является очень точным способом прогнозирования начала пескопроявления [28].

искусственная нейронная сеть была применена к трем скважинам месторождения Бонгкот Кетмали и Бандьопадхаем в 2018 году для определения отсутствия данных акустического и плотностного каротажа, где скважины А и Б не имели акустических данных, а скважина В не имела ни акустических, ни плотностных данных. Измеренные гамма-лучи, нейтронные и сопротивления трех скважин использовались вместе с акустическими и плотностными данными ближайших скважин в качестве узлов входных слоев. Когда акустические и плотностные данные были точно рассчитаны, песок можно было контролировать, и интервальные глубины трех скважин были проанализированы с обнаружением проблемных глубин песка и свободных от песка глубин. Метод искусственная нейронная сеть решил важные проблемы, поскольку до его использования применялись аналоговые методы для прогнозирования данных, которые были неточными в сравнении [29].

В 2019 году применили искусственная нейронная сеть, выполненную в MATLAB, для валидации прогнозирования пескопроявления по эмпирическому методу алгоритм многослойного перцептрона и геомеханическому моделированию. Алгоритм многослойного перцептрона валидирован с помощью искусственная нейронная сеть для значений отношения модуля сдвига к сжимаемости породы для прогнозирования начала пескопроявления, тогда как геомеханическому моделированию валидирован с помощью искусственная нейронная сеть в терминах предсказанного критическое депрессионное давление.

Искусственная нейронная сеть структурирована на основе рассчитанных механических свойств, которые валидированы измерениями керна и использованы в качестве узлов входного слоя системы. Она построена для выдачи результатов, соответствующих двум упомянутым методам для валидации их результатов. 70% данных были использованы для обучения, 15% для валидации и последние 15% для тестирования. Здесь искусственная нейронная сеть играла роль тестирования на валидность, где результаты валидации показали, что геомеханическому моделированию лучше, чем метод алгоритм многослойного перцептрона для прогнозирования пескопроявления [30].

Нейронные сети прямого распространения и опорных векторов построены с введением одиннадцати влияющих факторов во входной слой. Два метода валидированы с расчетными и полученными данными в исследовании [31].

Используя библиотеку Python, результаты появились как (1), что соответствует отсутствию песка, и (0), что соответствует существующей проблеме песка. Два алгоритма оценивались на основе критериев Шин как точность классификации, представленная:

1. Точность прогнозирования относительно общей прогнозируемой величины;
2. Матрица ошибок, которая информирует о производительности и правильности прогноза;
3. Точность истинно положительных результатов к сумме истинно положительных и ложно положительных, где результаты между нулем и единицей;
4. Полнота истинно положительных к отношению истинно положительных и ложно отрицательных, также результаты между нулем и единицей;
5. F1-Score как гармоническое среднее между точностью и полнотой;

6. Каппа Коэна, которая измеряет надежность показателей;

7. Функция потерь как среднеквадратичная ошибка.

Критерии сравнения двух методов с различными наборами размеров тестирования показали, что опорных векторов лучше, чем нейронные сети прямого распространения, особенно для бинарных подразделений с разреженными наборами обучающих данных. Матрица ошибок обоих методов относится к номерам скважин в терминах проблемного и свободного от песка в обоих состояниях прогнозирования и фактического. Доля тестирования 30% для опорных векторов была наилучшей, представляя фактические состояния как пять проблемных скважин по факту и прогнозу и три скважины без песка по факту и прогнозу.

Применение методов искусственного интеллекта в прогнозировании пескопроявления является весьма эффективным и обеспечивает хорошие результаты, как было объяснено в тексте. Исходя из критического обзора прогнозирования пескопроявления с помощью методов искусственного интеллекта, были сделаны следующие выводы:

1. Основным параметром, влияющим на точность результатов методов искусственного интеллекта, является наличие большого объема информации.
2. Различные методы искусственного интеллекта могут использоваться для прогнозирования проблемы начала пескопроявления либо путем определения критического депрессионного давления, либо с помощью числовых показателей вероятности начала пескопроявления, таких как ноль, один или минус/плюс один.
3. Различные методы искусственного интеллекта могут использоваться либо для сравнения полученных результатов с измеренными значениями с целью выбора наилучшего, либо для определения достоверности традиционных методов прогнозирования пескопроявления.
4. Существует множество факторов, влияющих на проблему пескопроявления, которые должны быть учтены в методы искусственного интеллекта, но ограничением ее использования является доступность данных.

Список литературы:

1. Wu B., Tan C.P., Lu N. Effect of Water Cut on Sand Production – An Experimental Study // SPE Production & Operations. 2006. Vol. 21, No. 3. P. 349–356.
2. Choi J.W. Geomechanics of Subsurface Sand Production and Gas Storage: Doctorate Dissertation / School of Civil and Environmental Engineering. Georgia Institute of Technology, 2011.
3. Osisanya S.O. Practical Guidelines for Predicting Sand Production // Proceedings of the Nigeria Annual International Conference and Exhibition. July 31–August 7, 2010. P. SPE-136980-MS.
4. Khamehchi E., Reisi E. Sand Production Prediction Using Ratio of Shear Modulus to Bulk Compressibility (Case Study) // Egyptian Journal of Petroleum. 2015. Vol. 24, Issue 2. P. 113–118.
5. McPhee C.A., Enzendorfer C.K. Sand Management Solutions for High-Rate Gas Wells, Sawan Field, Pakistan // Proceedings of the SPE International Symposium and Exhibition on Formation Damage Control. February 18–20, 2004. P. SPE-86535-MS.

6. Morita N., Boyd P.A. Typical Sand Production Problems: Case Studies and Strategies for Sand Control // Proceedings of the SPE Annual Technical Conference and Exhibition. October 6–9, 1991. P. SPE-22739-MS.
7. Lu Y., Xue C., Liu T., et al. Predicting the Critical Drawdown Pressure of Sanding Onset for Perforated Wells in Ultra-Deep Reservoirs with High Temperature and High Pressure // Energy Science & Engineering. 2021. Vol. 9. P. 1517–1529.
8. Kobbe W.M., Louis S., Mo. Problems Connected with the Recovery of Petroleum from Unconsolidated Sands // Proceedings of the SPE New York Meeting. New York, USA, 1917. P. SPE-917799-G.
9. Hall C.D. Jr, Harrisberger W.H. Stability of Sand Arches: A Key to Sand Control // Journal of Petroleum Technology. 1970. Vol. 22, No. 7. P. 821–829.
10. Kanj M.Y., Abousleiman Y. Realistic Sanding Predictions: A Neural Approach // Proceedings of the SPE Annual Technical Conference and Exhibition. October 3–6, 1999. P. SPE-56631-MS.
11. Geron A. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. O'Reilly Media, 2019.
12. Mohaghegh S. Virtual-Intelligence Applications in Petroleum Engineering: Part 1-Artificial Neural Networks // Journal of Petroleum Technology. 2000. Vol. 52, No. 9. P. 64–73.
13. McCulloch W.S., Pitts W. A Logical Calculus of the Ideas Immanent in Nervous Activity // Bulletin of Mathematical Biophysics. 1943. Vol. 5. P. 115–133.
14. Widrow B. Generalization and Information Storage in Networks of Adaline 'Neurons' // Self-Organizing Systems: Symposium Proceedings / Ed. by M.C. Yovitz, G.T. Jacobi, G. Goldstein. Washington, DC: Spartan Books, 1962. P. 435–461.
15. Alkinani H.H., Al-Hameedi A.T., Dunn-Norman S., et al. Applications of Artificial Neural Networks in the Petroleum Industry: A Review // Proceedings of the SPE Middle East Oil and Gas Show and Conference. March 18–21, 2019. P. SPE-195072-MS.
16. Sadiq T., Nashawi I.S. Using Neural Networks for Prediction of Formation Fracture Gradient // Proceedings of the SPE/CIM International Conference on Horizontal Well Technology. November 6–8, 2000. P. SPE-65463-MS.
17. Auer P., Burgsteiner H., Maass W. A Learning Rule for Very Simple Universal Approximators Consisting of a Single Layer of Perceptrons // Neural Networks. 2008. Vol. 21, No. 5. P. 786–795.
18. Mirjalili S. Genetic Algorithm // Evolutionary Algorithms and Neural Networks. Studies in Computational Intelligence. Vol. 780. Springer, Cham, 2018.
19. Kennedy J., Eberhart R. Particle Swarm Optimization // Proceedings of the IEEE International Conference on Neural Networks. Perth, Australia, 1995.
20. Amendolia S.R., Cossu G., Ganadu M.L., Golosio B., Masala G.L., Mura G.M. A Comparative Study of k-Nearest Neighbour, Support Vector Machine and Multi-Layer Perceptron for Thalassemia Screening // Chemometrics and Intelligent Laboratory Systems. 2003. Vol. 69, No. 1–2. P. 13–20.
21. Suykens J.A., Vandewalle J. Least Squares Support Vector Machine Classifiers // Neural Processing Letters. 1999. Vol. 9. P. 293–300.

22. Dong M., Long B., Lun L. Application of Logging Data in Predicting Sand Production in Oilfield // *Electronic Journal of Geotechnical Engineering*. 2013. Vol. 18, No. Z. P. 6173–618.
23. Oluyemi G.F., Oyeneyin B.M., Macleod C. UCS Neural Network Model for Real-Time Sand Prediction // *International Journal of Engineering Research in Africa*. 2010. Vol. 2. P. 1–13.
24. Master T. *Practical Neural Network Recipe in C++*. San Diego: Academic Press Inc., 1993.
25. Azad M., Zargar G., Arabjamaloei R., Hamzei A., Ekramzadeh M.A. A New Approach to Sand Production Onset Prediction Using Artificial Neural Networks // *Petroleum Science and Technology*. 2011. Vol. 29, No. 19. P. 1975–1983
26. Gharagheizi, F., Mohammadi, A. H., Arabloo, M., & Shokrollahi, A. (2017). Prediction of sand production onset in petroleum reservoirs using a reliable classification approach. *Petroleum*, 3(2), 280-285.
27. Moricca G., Ripa G., Sanfilippo F., Santarelli F.J. Basin Scale Rock Mechanics: Field Observations of Sand Production // *Proceedings of the SPE/ISRM Rock Mechanics in Petroleum Engineering*. August 1994. P. SPE-28066.
28. Olatunji O.O., Micheal O. Prediction of Sand Production from Oil and Gas Reservoirs in the Niger Delta Using Support Vector Machines (SVMs): A Binary Classification Approach // *Proceedings of the SPE Nigeria Annual International Conference and Exhibition*. July 31–August 2, 2017. P. SPE-189118-MS.
29. Ketmalee T., Bandyopadhyay P. Application of Neural Network in Formation Failure Model to Predict Sand Production // *Proceedings of the Offshore Technology Conference Asia*. March 20–23, 2018. P. OTC-28506-MS.
30. Sulaimon A.A., Teng L.L. Modified Approach for Identifying Weak Zones for Effective Sand Management // *Journal of Petroleum Exploration and Production Technology*. 2020. Vol. 10. P. 537–555.
31. Udebhulu D.O., Ogbe D.O. Mechanistic Models for Predicting Sand Production: A Case Study of Niger Delta Wells // *Proceedings of the SPE Nigeria Annual International Conference and Exhibition*. August 4–6, 2015. P. SPE-178279-MS.