

Федеральное государственное автономное образовательное учреждение высшего
образования

**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ТОМСКИЙ
ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

На правах рукописи

ДАВУДИ ШАДФАР

**ГИБРИДНАЯ ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ДЛЯ ОПЕРАТИВНОГО
ОПРЕДЕЛЕНИЯ СВОЙСТВ БУРОВОГО РАСТВОРА НА ОСНОВЕ
МАШИННОГО ОБУЧЕНИЯ**

Специальность: 2.3.1 – Системный анализ, управление и обработка информации

Диссертация на соискание ученой степени

кандидата технических наук

Научный руководитель:
PhD, доцент, Рукавишников В.С.

Томск – 2023

Содержание

Введение	5
ГЛАВА 1. Краткое введение в буровые растворы	13
1.1. Классификация и функции буровых растворов	13
1.2. Основные свойства буровых растворов	16
1.2.1. Реология бурового раствора	16
1.2.2. Водоотдача буровых растворов	26
1.2.3. Плотность бурового раствора	31
1.2.4. Содержание твердой фазы в буровом растворе	32
1.2.5. Вязкость бурового раствора, измеряемая с помощью воронки Марша	32
1.3. Измерение свойств бурового раствора.....	33
1.4. Краткое введение в машинное обучение	34
1.4.1. Основные концепции машинного обучения	34
1.4.2. Методы машинного обучения.....	36
1.5. Применение машинного обучения в разведке и разработке месторождений нефти и газа.....	38
1.5.1. Машинное обучение в разведке месторождений нефти и газа.....	39
1.5.2. Машинное обучение в технологиях добычи нефти и газа.....	43
1.5.3. Машинное обучение в разработке месторождений нефти и газа	46
1.5.4. Машинное обучение в буровом деле	49
1.6. Исторический обзор исследований в области прогнозирования свойств бурового раствора	54
ГЛАВА 2. Методология, применяемая в новой прогностической системе.....	61
2.1. Характеристика набора данных по буровых растворам.....	61
2.2. Теоретическое описание предиктивных алгоритмов	64
2.2.1. Метод наименьших квадратов опорных векторов (LSSVM).....	64
2.2.2. Метод многослойного экстремального машинного обучения (MELM).....	66
2.3. Алгоритмы оптимизации.....	69
2.3.1. Оптимизационный алгоритм с Cuckoo (COA)	69

2.3.2. Генетический алгоритм	72
2.4. Метрики погрешностей и оценки точности прогнозирования.....	74
2.5. Разработка гибридных моделей машинного обучения	76
2.5.1 Прогностические модели на основе оптимизации MELM генетическим алгоритмом и алгоритмом оптимизации с Cuckoo	77
2.5.2. Прогностические модели на основе оптимизации LSSVM генетическим алгоритмом и алгоритмом оптимизации Cuckoo	86
2.6. Последовательность действий	95
ГЛАВА 3. Эксперименты, проведенные для разработки прогнозных моделей	98
3.1. Оценка корреляций между зависимыми и независимыми переменными....	98
3.2. Обработка данных	100
3.2.1. Разделение данных для обучения и тестирования.....	100
3.2.2. Нормализация данных	102
3.2.3. Выявление и устранение выбросов	103
3.3. Определение оптимальной структуры моделей.....	106
3.3.1. Выбор ядра для LSSVM.....	107
3.3.2. Выбор оптимальной архитектуры для MELM	108
3.4. Настройка параметров алгоритмов оптимизации.....	113
3.5. Оптимизация гиперпараметров алгоритмов прогнозирования	118
3.5.1. Оптимизация гиперпараметров модели LSSVM	118
3.5.2. Оптимизация гиперпараметров модели MELM.....	124
ГЛАВА 4. Результаты прогнозирования гибридных моделей машинного обучения.....	128
4.1. Прогнозирование водоотдачи	128
4.2. Прогнозирование пластической вязкости.....	135
4.3. Прогнозирование динамического напряжения сдвига.....	142
4.5. Анализ значимости признаков для наилучшей модели прогнозирования.	149
4.4. Рекомендации для дальнейшей работы	152
Заключение.....	154

Номенклатура / аббревиатуры	156
Список использованных литератур	158
Приложение А	178
Свидетельства о государственной регистрации программ для ЭВМ	178
Приложение Б	181
Акты внедрения.....	181

Введение

Актуальность темы исследования. При бурении нефтяных и газовых скважин одним из наиболее технически сложных аспектов является работа с буровым раствором. Для повышения эффективности бурения скважин и минимизации потенциальных проблем, связанных с буровым раствором, инженеры по бурению должны определить оптимальную программу промывки скважины и определить компонентный состав раствора для каждой секции скважины. Им также необходимо периодически контролировать и измерять технологические свойства раствора в процессе бурения скважины. Для этого обычно используются экспериментальные методы контроля свойств бурового раствора путем прямого измерения в полевых лабораториях по месту бурения скважин. Такой подход может быть трудоемким и дорогостоящим, но он является необходимым в настоящее время для контроля технологического процесса бурения скважин. Среди всех свойств буровых растворов наиболее важными являются фильтрационные и реологические свойства. В связи с этим тщательное проектирование и приготовление буровых растворов с соответствующими реологическими и фильтрационными свойствами в сочетании с оперативным мониторингом имеют большое значение для успешного выполнения буровых работ. В процессе выполнения всего цикла буровых работ необходимо регулярно получать информацию относительно всех ключевых параметров буровых растворов. Как правило, реологические и фильтрационные свойства бурового раствора проверяются не чаще, чем один или два раза в день. Тем не менее, другие свойства бурового раствора, такие как плотность бурового раствора ($\rho_{бр}$), содержание твердой фазы (ТФ) и условная вязкость (УВ), как правило, контролируются несколько раз в час в силу простоты измерений.

Методы машинного обучения могут служить перспективным инструментом для оценки реологических и фильтрационных свойств бурового раствора на основе других легко и часто измеряемых параметров бурового раствора, таких как $\rho_{бр}$, ТФ и УВ. Метод наименьших квадратов опорных векторов (LSSVM) и метод

многослойного экстремального машинного обучения (MELM) — два метода машинного обучения, которые нашли свое успешное применение для решения различных задач регрессии и классификации. Эти методы могут быть использованы для разработки прогнозных моделей для точного определения вышеупомянутых свойств буровых растворов. Однако эти методы имеют свои недостатки, которые негативно влияют на точность прогнозирования и обобщаемость. В этом отношении автономная модель LSSVM страдает от локальной оптимизации, используемой для определения оптимальных гиперпараметров модели, которая склонна к падению до локальных минимумов, а автономная модель MELM требует трудоемкого анализа методом проб и ошибок для определения правильной архитектуры модели и страдает от случайного назначения гиперпараметров. Эти проблемы с методами MELM и LSSVM могут быть решены путем объединения автономных моделей с методами глобальной оптимизации для определения оптимальной архитектуры модели MELM и оптимальных гиперпараметров для обеих моделей MELM и LSSVM.

Наконец, стоит отметить, что, получение подобной информации о фильтрационных и реологических свойствах растворов в режиме реального времени позволит избежать осложнений, связанных с изменением свойств буровых растворов во время бурения, путем раннего выявления и своевременного принятия необходимых корректирующих действий. Решение данной задачи также приближает нас к достижению полной автоматизации прогнозирования реологических и фильтрационных свойств буровых растворов непосредственно в полевых условиях.

Степень разработанности темы. Данную тематику изучали такие исследователи, как А. Алсабаа (Саудовская Аравия, 2021), С. Элькататный (Саудовская Аравия, 2017), А. Говида (Саудовская Аравия, 2020), О. Томива (Нигерия, 2019), С. Гюль (США, 2020), А. Лекомцев, К. Абдельгавад (Россия, 2022), И. Гомаа (Саудовская Аравия, 2021), М. Рази (Иран, 2013), А. Третьяк (Россия, 2022), Р. Голами (Норвегия, 2022). Постоянный мониторинг и регулярное измерение реологических и фильтрационных свойств буровых растворов крайне

важны для оптимизации буровых работ. Своевременное получение информации об этих свойствах позволяет буровой бригаде быстро принимать необходимые меры по регенерации бурового раствора. Существует ряд исследований, направленных на разработку интеллектуальных моделей для прогнозирования вышеупомянутых свойств, с ограниченной практической применимостью по причине ограничений по конкретным типам буровых растворов, а также по причине недостижения оптимального решения задачи. Кроме того, в настоящее время не разработано модели машинного обучения, способной прогнозировать объем фильтрации буровых растворов на основе наиболее часто отслеживаемых параметров ($\rho_{б,р}$, ТФ и УВ). Таким образом, в настоящее время существует актуальная проблема разработки прогностических моделей с высокой обобщающей способностью для прогноза трех целевых параметров, которые могут быть использованы в качестве системы помощи в принятии решений.

Цель исследования. Целью данного исследования является разработка и оптимизация моделей машинного обучения для точного определения трех критических параметров буровых растворов, а именно водоотдачи, пластической вязкости и динамического напряжения сдвига, на основе других легко и регулярно измеряемых свойств бурового раствора.

Для достижения поставленной цели в диссертации необходимо решить следующие задачи:

- Провести обзор существующих методов для прогнозирования трех целевых параметров бурового раствора, включая методы в основе которых лежит искусственный интеллект.
- Разработать две автономные модели машинного обучения (MELM и LSSVM) для прогнозирования целевых параметров буровых растворов. Комбинировать разработанные модели машинного обучения с методами оптимизации для определения оптимальной структуры и гиперпараметров моделей с целью повышения точности прогнозирования и обобщаемости моделей.

- Провести серию экспериментов и анализов на этапе обучения моделированию гибридных моделей для повышения их точности прогнозирования и обобщаемости.
- Применить предложенные автономные и гибридные модели для прогнозирования целевых параметров бурового раствора; провести оценку эффективности разработанных моделей.

Объектом исследования в данной работе являются важнейшие фильтрационные и реологические свойства буровых растворов на водной основе: водоотдача, пластическая вязкость и динамическое напряжение сдвига.

Предметом исследования является прогнозная интеллектуальная модель для определения свойств бурового раствора на водной основе.

Методы исследования. Проведенное в данной диссертации исследование основано на методах машинного обучения, методах глобальной оптимизации, математическом и статистическом анализе, а также аналитических и численных экспериментах. Все вычисления проводились с использованием вычислительной платформы MATLAB.

Научная новизна работы.

1. Предложена, обоснована и экспериментально проверена прогнозирующая модель, основанная на многослойном экстремальном обучении (MELM), обеспечивающая повышение точности прогнозирования свойств бурового раствора с помощью определения оптимального количества скрытых слоев и входящих в них нейронов, а также нахождения оптимальных значений весов и смещений, приписываемых каждому нейрону и скрытому слою соответственно.
2. Предложена, обоснована и экспериментально проверена прогнозирующая модель, основанная на методе опорных векторов (LSSVM), обеспечивающая повышение точности прогнозирования свойств бурового раствора за счет определения подходящей функции ядра и организации поиска гиперпараметров, при которых достигается глобальный минимум среднеквадратического отклонения (RMSE).

3. Предложено применение разработанных прогнозирующих моделей для формирования набора гибридных моделей, обеспечивающих получение точных оценок водоотдачи, пластической вязкости и динамического напряжения сдвига бурового раствора на основе измеряемых параметров: плотности, условной вязкости и содержания твердой фазы бурового раствора.

Теоретическая значимость работы. Теоретические положения, сформулированные автором, способствуют развитию гибридных моделей машинного обучения, позволяющих делать точные прогнозы с высокой обобщаемостью. Задача разработки таких гибридных прогностических моделей выполнена с использованием методов глобальной оптимизации и получила научное обоснование в результате проведения аналитического описания и многочисленных вычислительных экспериментов над предложенными моделями.

Практическая значимость работы. Практическая значимость работы заключается в том, модели, предложенные в данной диссертации, могут быть применены при бурении скважин для частого определения трех критических параметров бурового раствора, а именно пластической вязкости, динамическое напряжение сдвига и водоотдачи. Применение таких моделей, генерирующих надежные прогнозы целевых параметров бурового раствора, снижает требования к проведению большого количества трудоемких экспериментальных измерений.

Положения, выносимые на защиту.

1. Предложенная прогнозирующая модель, основанная на многослойном экстремальном обучении, обеспечивает повышение точности прогнозирования свойств бурового раствора с применением оптимальной архитектуры MELM на 35–62 % в зависимости от целевого параметра по сравнению с традиционным подходом.
2. Предложенная прогнозирующая модель, основанная на методе опорных векторов LSSVM, обеспечивает повышение точности прогнозирования свойств бурового раствора на 19–45 % по сравнению с традиционным подходом.
3. Разработанные гибридные модели машинного обучения позволяют определять водоотдачу, пластическую вязкость и динамическое напряжение сдвига

буровых растворов с погрешностями (2,95 – 4,27) %, (1,27 – 1,73) %, и (1,83 – 2,42) % соответственно.

Достоверность результатов. Достоверность результатов, представленных в диссертационном исследовании, обеспечивается путем оценки эффективности прогнозирования разработанных моделей на тестовом наборе данных. Предложенные прогностические модели, примененные к тестовому набору данных, обеспечивают достоверные прогнозы трех целевых параметров.

Внедрение результатов работы. Результаты настоящего диссертационного исследования внедрены в учебный процесс Инженерной школы природных ресурсов ТПУ, а также используются в компании ООО "Инновационные Технологии" для нужд мониторинга процесса бурения. Акты внедрения приложены к диссертационной работе.

Апробация работы. Основные положения диссертационного исследования докладывались и обсуждались на следующих конференциях:

- 3-й Восточно-Средиземноморский семинар EAGE (1–3 декабря 2021 года, Ларнака, Кипр);
- XXVI Международный научный симпозиум имени академика М.А. Усова «Проблемы геологии и освоения недр» (4–8 апреля 2022 года, Томск),
- XXVII Международный научный симпозиум имени академика М.А. Усова «Проблемы геологии и освоения недр» (3–7 апреля 2023 года, Томск), и
- Тюменская нефтегазовая конференция (4–8 сентября 2023, Минеральные Воды).

Публикации по теме диссертации. По результатам диссертационного исследования опубликовано 12 работ, в том числе 9 статей в журналах первого квартиля (Q1), проиндексированных в базах данных Web of Science и Scopus, а также 3 публикации в материалах международных и всероссийских научных конференций; получено 3 свидетельства о государственной регистрации программ для ЭВМ.

Личный вклад автора. Все описанные исследования проведены автором лично. Автором составлен необходимый набор данных на основе ежедневных буровых сводок по двум месторождениям и проведена предварительная обработка набора данных для машинного обучения и моделирования целевых параметров. Все этапы разработки и оценки предложенного метода прогнозирования свойств бурового раствора выполнены автором лично. Все результаты достигнуты и интерпретированы автором лично. Концептуализация исследования, постановка цели и задач настоящего исследования осуществлялись автором совместно с научным руководителем.

Структура и объем работы. Настоящее диссертационное исследование включает в себя список таблиц, список рисунков, введение, четыре основные главы, заключение, список номенклатуры и библиографию. Объем диссертационного исследования составляет 182 страниц, включая 52 рисунков и 22 таблицы. Библиография состоит из 165 наименований.

Во введении обосновывается актуальность темы диссертации, формулируется цель настоящего научного исследования, определяются задачи, подлежащие решению, определяется научная новизна и значимость результатов работы с точки зрения теоретической и практической ценности.

В первой главе приводятся определения буровых растворов, их классификация, характеристики, методы измерения параметров буровых растворов. Кратко представлены основы методов машинного обучения и всесторонне рассмотрены области их применения в нефтегазовой отрасли.

Во второй главе подробно рассмотрено теоретическое описание алгоритмов, применяемых для разработки предложенных моделей прогнозирования, статистические метрики, используемые для оценки точности прогнозирования моделей, характеристика рассматриваемого набора данных, а также подходы, применяемые для разработки гибридных моделей машинного обучения.

В третьей главе представлены и подробно проанализированы вычислительные эксперименты, проведенные на каждом этапе разработки и оценивания предложенных гибридных моделей машинного обучения.

В четвертой главе представлены, проанализированы и обоснованы результаты прогнозирования, полученные с помощью автономных и гибридных моделей, разработанных для прогнозирования целевых параметров буровых растворов.

Благодарности. Прежде всего, автор выражает огромную благодарность своему научному руководителю Валерию Рукавишникову за его постоянные научные и технические консультации и поддержку на всех этапах данного исследования. Благодарит своих коллег Дэвида Вуда, Мохаммада Мехрада, Грачика Еремяна, и Тамару Шульгину за их научные консультации, которые помогли улучшить настоящее исследование. И последнее, но не менее важное, автор искренне благодарит Салара Мардани, супервайзера по бурению Национальной иранской буровой компании за его помощь в сборе данных, использованных в настоящем исследовании.

ГЛАВА 1. Краткое введение в буровые растворы

Перед изложением методологии и результатов исследования, нам видится целесообразным предоставить общую информацию о предмете исследования в объеме, достаточном для понимания. Таким образом, первая глава исследования посвящена буровым растворам и их классификации, рабочим характеристикам и методам измерения параметров. В настоящем исследовании в силу сложности решаемых задач применялись методы машинного обучения. В этой связи в главе также будут освещены методы машинного обучения и области их применения в нефтегазовой промышленности.

1.1. Классификация и функции буровых растворов

Буровой раствор или промывочная жидкость является критически важным компонентом процесса роторного бурения. Основные функции бурового раствора заключаются в удалении бурового шлама из ствола скважины в ходе бурения, а также предотвращении притока в ствол скважины флюидов из вскрываемых пластов [1,2]. Буровые растворы выполняют также ряд других важных функций, которые будут изложены далее [1,3–5]. Поскольку буровые растворы являются неотъемлемой частью процесса бурения, многие проблемы, возникающие в ходе строительства скважин, могут быть непосредственно или косвенно вызваны применяемыми растворами. Таким образом, выбор и/или разработка рецептур буровых растворов должны осуществляться тщательным образом, чтобы обеспечить правильное выполнение всех проектных функций [1–11].

Буровые растворы, как правило, подразделяются на три основные категории, а именно: растворы на водной, нефтяной и синтетической основе [1,3,12–15]. Несмотря на более высокую производительность по сравнению с буровыми растворами на водной основе, применение растворов на нефтяной и синтетической основе зачастую связано с негативным воздействием на окружающую среду и высокими издержками, особенно при глубоком бурении [4,13,14,16]. Таким образом, буровые растворы на водной основе, несмотря на более низкую

эффективность, являются предпочтительными [1,14,17]. В этой связи представляется необходимым компенсировать ограничения, присущие буровым растворам на водной основе, за счет применения новых стратегий и рецептов [4,12]. Более того, именно растворы на водной основе наиболее часто применяются в буровых работах [1,3,4,6,8].

Буровой раствор готовится бригадой непосредственно на буровой площадке в соответствии с заранее заданной программой и закачивается в ствол скважины. На рисунке 1.1 представлен типовой процесс циркуляции бурового раствора. Как видно из рисунка, буровой раствор подается с буровых насосов через наземный трубопровод, стояк и буровой шланг в бурильную трубу. После этого буровой раствор через форсунки долота попадает на забой скважины и выносит буровой шлам на поверхность по кольцевому зазору между бурильной трубой и пластом или обсадной колонной. После возвращения на поверхность буровой раствор проходит через вибросита и иное оборудование для отделения твердых частиц, где раствор очищается от шлама. Далее раствор снова попадает в буровые емкости, что обеспечивает его циркуляцию [4,5,8,16].




Рисунок 1.1 – Процесс циркуляции бурового раствора [4].

В ходе бурения циркулирующий буровой раствор, как правило, обеспечивает выполнение следующих функций:

- Контроль пластового давления, предотвращение газонефтеводопроявлений [4,10,18];
- Удаление выбуренной породы с поверхностей долот и подъем ее на поверхность [19];
- Поддержание механической и химической устойчивости ствола скважины [20–22];
- Передача гидравлической энергии на буровое долото и скважинный инструмент [20,22];
- Охлаждение и смазка бурильной колонны и долота [5,20,21];
- Обеспечение качества проводимых геофизических исследований [4,20];
- Обеспечение процессов освоения скважины для ввода ее в эксплуатацию [1,3–5];
- Обеспечение удержания твердых частиц в подвешенном состоянии или минимизация их осаждения на забой при остановке циркуляции с сохранением возможности удаления твердых частиц в наземной системе обработки [1,3–5]; а также,
- Формирование низкопроницаемой тонкой и твердой глинистой корки на вскрываемой поверхности проницаемых пластов [1,3–5,23].

Как говорилось выше, буровые растворы выполняют ряд функций, качество выполнения которых обусловлено двумя факторами: геологическими характеристиками пласта и свойствами бурового раствора [24]. Учитывая, что на геологические характеристики пласта повлиять нельзя, для обеспечения надлежащей эффективности бурового раствора инженер–бурильщик должен обладать всеобъемлющими знаниями и пониманием свойств бурового раствора и механизмов их влияния на каждую из функций.

1.2. Основные свойства буровых растворов

Для использования в процессе бурения нефтяных и газовых скважин, буровые растворы должны обладать различными целевыми параметрами, такими как плотность, вязкость, водоотдача, pH, содержание твердых частиц, устойчивость и т.д. Свойства бурового раствора проектируются, исходя из эксплуатационных и скважинных условий, а также физико–геологических свойств вскрываемого пласта. В ходе буровых работ буровые растворы подготавливаются и модифицируются для обеспечения заданных свойств, необходимых для бурения определенного интервала скважины [16]. Мониторингом свойств буровых растворов на площадке скважины занимается бригада по буровым растворам в специализированной лаборатории. Среди всех свойств буровых растворов наиболее важными считаются реологические и фильтрационные свойства, так как успех бурения напрямую связан с этими двумя свойствами [6,7,25]. В следующих разделах представлены шесть основных свойств бурового раствора, которые в контексте настоящего исследования рассматриваются как входные и/или выходные данные разработанных прогностических моделей.

1.2.1. Реология бурового раствора

Реология – это наука о деформации и потоке материи. Путем определенных изменений возможно установить, каким образом та или иная жидкость будет течь при различных условиях, включая температуру, давление и скорость сдвига. Вязкость жидкости – ее физическое свойство, отражающее сопротивление жидкости потоку [1]. Вязкость может быть рассчитана путем построения графика напряжения сдвига как функции скорости сдвига. Следовательно, единицей измерения вязкости является Па·с (паскаль–секунда). Другой распространенной единицей, используемой для измерения вязкости, является пуаз. Поскольку пуаз является крупномасштабной единицей измерения, как правило, используется сантипуаз (сП), который равен одному Па·с. Скорость сдвига (сек^{-1}) представляет собой градиент скорости, dV/dH , и является мерой скорости перемещения слоев относительно друг друга. Она описывает эффект сдвига, который испытывает

жидкость ($\dot{\gamma}$), а его единицей измерения является величина обратная секунда (сек⁻¹). Кроме того, для описания вязкости жидкости, помещенной между двумя пластинами, используется напряжение сдвига (Н/м², Па). Напряжением сдвига называется сила на единицу площади (F/A), необходимая для осуществления сдвигового действия (τ). Для расчета напряжения сдвига используется следующее уравнение [1,5,11]:

$$\tau = \frac{F}{A}, \quad (1.1)$$

где F — сила Н, а A — площадь, м².

Таким образом, динамическую вязкость (μ) можно определить с помощью следующего уравнения:

$$\mu = \frac{\tau}{\dot{\gamma}}. \quad (1.2)$$

Вязкость ньютоновской жидкости измеряется в Па·с. Для неньютоновской жидкости применяется термин «кажущаяся вязкость» (КВ) (μ_a).

На рисунке 1.2 представлен сдвиг жидкости между двумя параллельными пластинами. Пространство между двумя параллельными пластинами, расположенными на расстоянии (H) друг от друга, заполнено жидкостью. Верхняя пластина с площадью поверхности (A) перемещается со скоростью (V) под действием силы (F), в то время как нижняя пластина остается неподвижной. Верхний слой жидкости, прилегающий к верхней пластине, движется вместе с пластиной со скоростью (V), в то время как нижний слой жидкости, прилегающий к нижней пластине, остается неподвижным и имеет нулевую скорость. В результате в пространстве между двумя пластинами образуется градиент скорости (dV/dH), где dV относится к разнице скоростей между соседними слоями жидкости, а dH относится к дифференциальной толщине слоя жидкости [4,20].




Рисунок 1.2 – Определение вязкости посредством модели с двумя пластинами [4].

Основываясь на реакции на скорость сдвига, жидкости обычно классифицируются как ньютоновские и неньютоновские [13,26]. Ньютоновская модель описывает простейшее поведение потока жидкости, где вязкость жидкости — линейная константа пропорциональности между напряжением сдвига и скоростью сдвига в условиях постоянной температуры и давления. Ньютоновские жидкости начинают течь незамедлительно, и напряжение сдвига увеличивается по мере увеличения скорости сдвига. Многие жидкости, в том числе вода, масло, бензин, спирт и глицерин, ведут себя как ньютоновские жидкости; их вязкость зависит только от состояния жидкости и ее температуры. Для ньютоновских жидкостей график напряжения сдвига относительно скорости сдвига представляет собой прямую линию, которая проходит через начало координат графика, а угол наклона этой линии называется ньютоновской, или динамической, вязкостью жидкости (см. рисунок 1.2) [18,27].

Большинство жидкостей не являются ньютоновскими. Для этих жидкостей не существует константы пропорциональности между напряжением сдвига и скоростью сдвига; их вязкость изменяется с изменением скорости сдвига [27].

Буровые растворы в скважинных условиях в основном демонстрируют неньютоновское поведение. Поведение жидкости может быть выражено с использованием различных реологических моделей, таких как модели Гершеля–

Балкли, степенного закона и пластической модели Бингама [8]. Общие реологические модели буровых растворов могут быть кратко описаны следующим образом:

Реологические модели — это математические модели, используемые для описания взаимосвязи между скоростью сдвига и напряжением сдвига для ньютоновской жидкости, в которой вязкие напряжения, возникающие при ее течении, в каждой точке линейно коррелируют с локальной скоростью деформации (см. Рисунок 1.3а) и неньютоновскими жидкостями, которые являются жидкостями, не следующими закону вязкости Ньютона. Для реологической оценки нефтепромысловых жидкостей обычно используется концентрический цилиндрический вискозиметр (например, вискозиметр FANN). Приборы такого типа обеспечивают ограниченное количество скоростей сдвига в диапазоне от 3 об/мин ($5,1 \text{ сек}^{-1}$) до 600 об/мин (1022 сек^{-1}). Полученные данные анализируются с использованием реологических моделей с целью определения реологических свойств [3,5,11].

Как упоминалось ранее, большинство буровых растворов характеризуются неньютоновским поведением. Степенной закон, модель Гершеля–Балкли и модель Бингама являются тремя наиболее часто применяемыми математическими моделями для описания неньютоновского поведения буровых растворов. Для описания реологического поведения большинства типов неньютоновских жидкостей часто применяется комбинация этих моделей [20,21]. На рисунке 1.3 показаны четыре наиболее распространенные реологические модели для ньютоновской (рисунок 1.3а) и неньютоновских жидкостей (рисунки 1.3б, 1.3в и 1.3г), используемые в инжиниринге буровых растворов [1,3–5]. Краткое описание этих трех моделей приводится далее.

а) Степенной закон. Модель степенного закона предлагает хорошее описание взаимосвязи между напряжением сдвига и скоростью сдвига псевдопластических жидкостей и, следовательно, применима для большинства типов буровых растворов (см. рисунок 1.3б). Преимущество модели степенного закона

заключается в том, что она может быть использована при любых значениях скорости сдвига, особенно при низких. Эта модель является альтернативой модели Бингама, поскольку последняя предназначена для описания характеристик течения жидкости только в ограниченной степени. Таким образом, метод степенного закона более качественно описывает характеристики течения жидкости по сравнению с моделью Бингама [7,28].

в) Модель Гершеля–Балкли. Данная модель является модифицированной версией модели Степенного закона. Она наилучшим образом подходит для описания реологических свойств жидкостей с нелинейным поведением, имеющих предел текучести (см. рисунок 1.3г). Наилучшие результаты модель показывает при измерении параметров буровых растворов при более низких скоростях сдвига [2,22,29].

с) Пластическая модель Бингама. Пластическая модель Бингама, благодаря своей простоте и адаптивности к пределу текучести, характерному для большинства буровых растворов, является наиболее распространенной реологической моделью, используемой в буровой отрасли. Данная модель представляет собой двухпараметрическую модель, включающую в себя предел текучести и пластическую вязкость жидкости (см. рисунок 1.3в) [27].

Такие модели применяются для определения реологических свойств буровых растворов, таких как кажущаяся вязкость (КВ), динамическое напряжение сдвига (ДНС), пластическая вязкость (ПВ), консистенция жидкости (К) и реологическое поведение (n). Реологические параметры, в частности, требуются для определения эквивалентной плотности циркуляции (ECD) [1], потерь давления жидкости в системе циркуляции, эффективности промывки ствола скважины и профиля потока. Кроме того, реологические свойства буровых растворов оказывают значительное влияние на скорость проходки (ROP) при бурении. Известно, что увеличение пластической вязкости является результатом высокого содержания твердых веществ в буровом растворе и приводит к снижению скорости проходки.

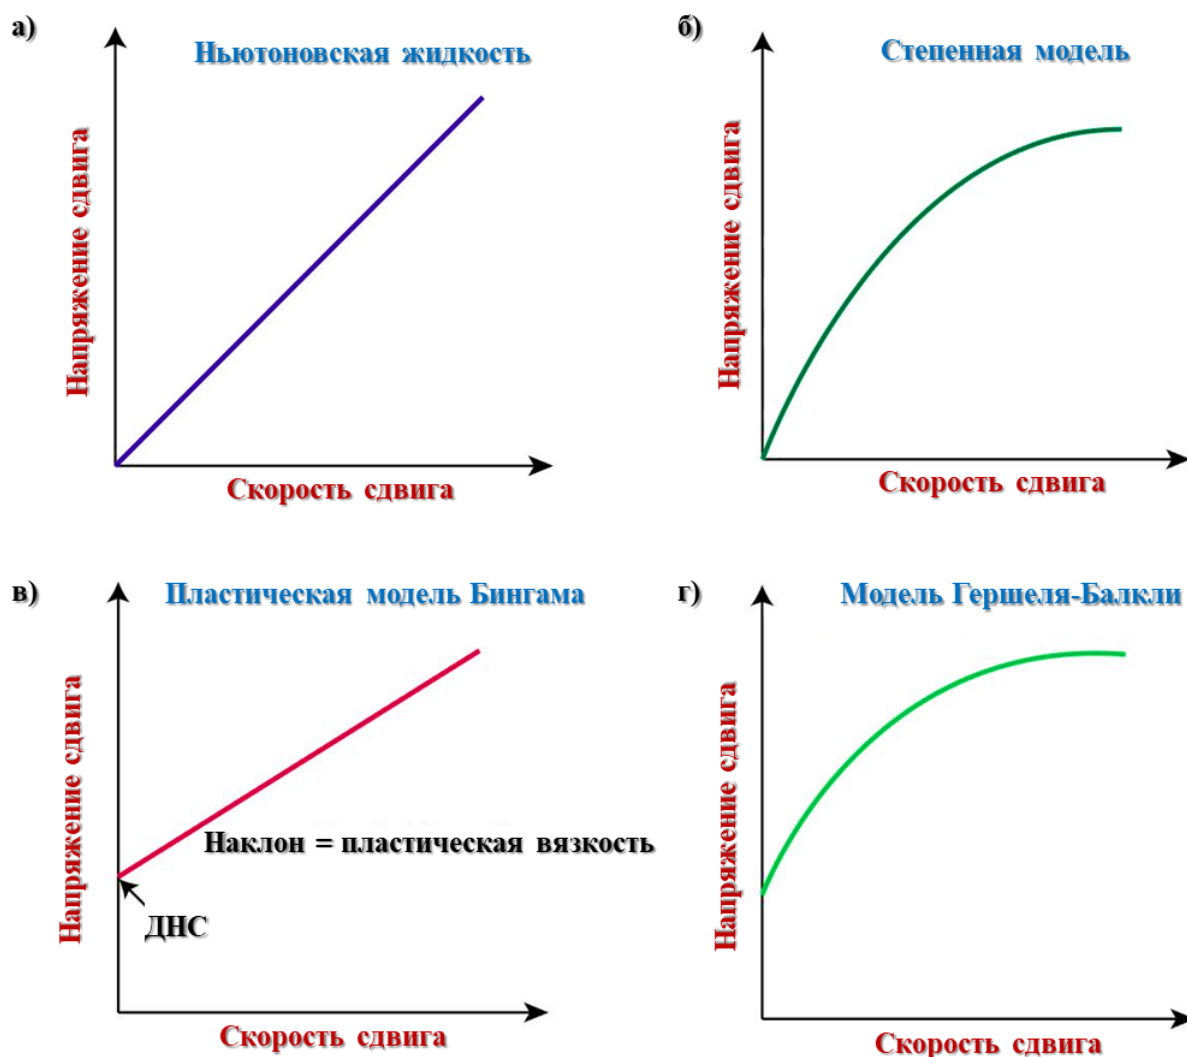


Рисунок 1.3 – Реологические модели буровых растворов [27].

Применение буровых растворов с неблагоприятными реологическими параметрами обычно приводит к недостаточной промывке ствола скважины, что также снижает скорость проходки, что, как правило, приводит к значительному увеличению общей стоимости бурения [2,11].

Пластическая модель Бингама чаще всего используется в полевых условиях для измерения реологических свойств бурового раствора в силу своей простоты и того факта, что большинство буровых растворов не являются ньютоновскими жидкостями и обладают динамическим напряжением сдвига. Далее приводится краткое описание данной модели.

Пластическая модель Бингама является одной из старейших и наиболее популярных реологических моделей, используемых в настоящее время. Данная

модель описывает жидкость, требующую приложения конечной силы для инициирования потока (динамическое напряжение сдвига), и которая затем проявляет постоянную вязкость при увеличении скорости сдвига (пластическую вязкость). Математическое описание модели Бингема приведено следившем уравнении [1,3–5]:

$$\tau = \tau_o + \mu_p \gamma, \quad (1.3)$$

где τ – напряжение сдвига, τ_o – динамическое напряжение сдвига или же напряжение сдвига при нулевой скорости сдвига (точка пересечения с осью γ), μ_p – пластическая вязкость или скорость увеличения напряжения сдвига с увеличением скорости сдвига (наклон линии). и γ – скорость сдвига.

Большинство буровых растворов не являются истинными бингамовскими пластическими жидкостями. Для типового бурового раствора, если кривая консистенции была построена с помощью данных вращательного вискозиметра, образуется нелинейная кривая, не пересекающая начало координат, как показано на рисунке 1.4 [2,4].




Рисунок 1.4 – Ньютоновская жидкость и типовой буровой раствор [11].

Как видно на рисунке 1.4, развитие прочности геля приводит к тому, что пересечение с осью γ происходит в точке выше начала координат из-за

минимальной силы, необходимой для разрушения геля и инициации течения. Поршневое течение, состояние, при котором гелеобразная жидкость течет подобно «поршню» с плоским профилем вязкости, инициируется по мере увеличения этой силы. По мере увеличения скорости сдвига происходит переход от поршневого к вязкому течению. В области вязкого течения равные приращения скорости сдвига вызывают равные приращения напряжения сдвига, и система принимает характер потока ньютоновской жидкости [11].

Для измерения динамического напряжения сдвига и пластической вязкости по Бингаму был разработан двухскоростной вискозиметр. Кривая течения типового бурового раствора, построенная с помощью двухскоростного вискозиметра FANN, приведена на рисунке 1.5. Наклон прямолинейной части этой кривой отражает пластическую вязкость. По двум измерениям напряжения сдвига кривая пластической вязкости может быть экстраполирована к оси Y для определения динамического напряжения сдвига по Бингаму, которое соответствует точке пересечения с осью Y . Для большинства буровых растворов истинный предел текучести ниже ДНС по Бингаму, как показано на рисунке 1.5.



Рисунок 1.5 – Результаты применения пластической модели Бингама к двум измерениям [11].

Как уже упоминалось, пластическая модель Бингама оперирует двумя параметрами, описывающими поведение буровых растворов, а именно, пластической вязкостью и динамическим напряжением сдвига. Эти свойства измеряются непосредственно в ходе бурения с целью мониторинга реологических свойств бурового раствора в ходе буровых работ [5].

Динамическое напряжение сдвига

Динамическое напряжение сдвига, второй компонент сопротивления течению бурового раствора, является количественной оценкой электрохимических сил (сил притяжения) в буровом растворе. Эти силы являются продуктом отрицательных и положительных зарядов, расположенных на поверхности или вблизи поверхности частиц. Динамическое напряжение сдвига является мерой этих сил при течении бурового раствора и определяется следующими факторами: (1) поверхностными свойствами частиц твердой фазы, (2) объемной концентрацией твердой фазы и (3) электрическими полями твердой фазы (концентрацией и типами ионов в жидкой фазе бурового раствора). Высокая вязкость, результирующая из высоких значений динамического напряжения сдвига или сил притяжения, может быть вызвана [1,3–5,11]:

1. Введением растворимых загрязняющих веществ, таких как соли, цемент, ангидрит или гипс, что приводит к флокуляции глин и химически активных частиц твердой фазы.
2. Разрушением частиц глины долотами и бурильной трубой, что создает новые остаточные силы за счет разрыва валентности связи на сломанных краях частиц. Данные силы имеют тенденцию к стягиванию частиц в дезорганизованной форме или в хлопья.
3. Введением твердых инертных веществ в систему, что повышает значение динамического напряжения сдвига за счет взаимного притяжения частиц, которое увеличивается при уменьшении расстояния между ними.
4. Разбуриванием гидратируемых сланцев или глин, что вводит в систему новые активные твердые вещества, увеличивая силы притяжения за счет сближения частиц и увеличения общего количества зарядов.

5. Недостаточной или чрезмерной обработкой электрохимически заряженными химическими веществами, что увеличивает силы притяжения.
6. Применением разветвленных биополимеров.
7. Чрезмерным применением органофильных глин или реологических модификаторов в инвертно-эмульсионных системах [4].

Динамическое напряжение сдвига, измеряемое в фунтах на 100 квадратных футов (фунт / 100 фут²), рассчитывается на основе показаний вискозиметра FANN, как показано следующим уравнением [11]:

$$\text{ДНС} \left(\frac{\text{lb}}{100 \text{ft}^2} \right) = 2\theta_{300} - \theta_{600}, \quad (1.4)$$

где θ_{300} и θ_{600} соответствуют показаниям прибора при скоростях вращения ротора 300 и 600 об/мин [4].

Пластическая вязкость

Пластическая вязкость обычно описывается как часть сопротивления течению, вызванная механическим трением. Она обусловлена в первую очередь, концентрацией, размером и формой твердых частиц, вязкостью жидкой фазы, присутствием длинноцепных полимеров, отношением нефти или синтетических материалов к воде в инвертно-эмульсионных растворах, а также типом эмульгатора [4].

Твердая фаза является основным объектом внимания инженера по буровым растворам. Увеличение пластической вязкости может подразумевать увеличение концентрации твердых частиц, уменьшение размера твердых частиц, изменение формы частиц или комбинацию вышеуказанных факторов. Любое увеличение общей площади поверхности твердых частиц в буровом растворе приведет к увеличению пластической вязкости. Например, разделение твердой частицы на две половины приведет к образованию двух частиц, суммарная площадь открытой поверхности которых будет превышать площадь исходной частицы.

Плоская частица имеет большую площадь поверхности, чем сферическая частица того же объема. Однако в большинстве случаев увеличение пластической

вязкости является результатом повышения концентрации твердой фазы. Это может быть верифицировано путем анализа изменения плотности и / или ретортного анализа.

Пластическая вязкость, измеряемая в сантипуазах (сП) или миллипаскалях в секунду (мПа•с) рассчитывается на основе показаний вискозиметра в соответствии с следившем уравнением:

$$ПВ(СП) = \theta_{600} - \theta_{300}, \quad (1.5)$$

где θ_{300} и θ_{600} соответствуют показаниям прибора при скоростях вращения ротора 300 и 600 об/мин [4].

1.2.2. Водоотдача буровых растворов

Многие пласты, вскрываемые бурением, обладают достаточно высокой проницаемостью, что приводит к проникновению в них фильтрата бурового раствора [30,31]. Проницаемый пласт выступает в качестве фильтрующего материала, а коллоидные твердые частицы выбуренных пород и утяжелителя накапливаются на поверхности стенки скважины, образуя глинистую корку (см. Рисунок 1.6). Часто проводят различие между частицами, проникающими в призабойную зону пласта и формирующими внутренний слой глинистой корки, и частицами, оседающими на поверхности пласта и формирующими внешний слой глинистой корки.

Одной из задач инженеров по буровым растворам является определение объема фильтрата (водоотдачи) бурового раствора и его снижение, что обусловлено следующими причинами [2,32]:

1. Фильтрат может снизить проницаемость коллектора, что приведет к снижению производительности скважины, пропорциональному глубине проникновения фильтрата в пласт. Таким образом, снижение объема фильтрата может повысить продуктивность скважины.

2. Попадание фильтрата в глинистые прослойки может вызвать набухание глин с последующим их оползанием в ствол скважины, что способно привести к

прихвату бурового инструмента. Таким образом, сокращение водоотдачи может снизить риск возникновения осложнений при бурении.

3. Проникновение фильтрата бурового раствора в пласт приводит к искажению данных электрокаротажа, пропорциональному глубине проникновения фильтрата в пласт. Не имея информации о глубине проникновения, мы не можем точно интерпретировать кривые электрокаротажей.




Рисунок 1.6 – Формирование глинистой корки на поверхности проницаемого пласта.

Существует два типа водоотдачи: динамическая и статическая [32].

- **Динамическая водоотдача**

Если в ходе бурения имеет место быстрое поглощение фильтрата пластом, на стенке ствола скважины образуется еще один слой глинистой корки. Таким образом, толщина и прочность корки увеличиваются, при этом корка продолжает размываться буровым раствором и подвергаться механическому воздействию от контакта с буровой трубой. Если скорость образования глинистой корки равна скорости ее разрушения, ее толщина не изменяется, и водоотдача удерживается на постоянном уровне.

Процесс фильтрации бурового раствора в пласт в ходе циркуляции называется динамической водоотдачей. Динамическая фильтрация характеризуется тонкой глинистой коркой и существенными потерями фильтрата в пласт. Динамическая фильтрация, наряду с состоянием пласта, перепадом

давления, вязкостью, содержанием и размерами твердых частиц, оказывает влияние на реологические свойства бурового раствора. Толщина глинистой корки связана со скоростью и характером циркуляции бурового раствора. При высокой скорости циркуляции глинистая корка подвергается серьезному эрозионному воздействию, что приводит к уменьшению толщины корки и повышению водоотдачи. Эрозия, создаваемая турбулентным течением, более деструктивна, чем создаваемая ламинарным, в этой связи водоотдача при турбулентном характере циркуляции бурового раствора в стволе скважины выше [27,33].

- **Статическая водоотдача**

Для проведения спуско–подъемных работ или ликвидации осложнений циркуляцию в стволе скважины приостанавливают, и глинистая корка более не подвергается эрозионному воздействию бурового раствора [1]. По мере поглощения фильтрата бурового раствора пластом прочность глинистой корки повышается, темп поглощения падает, и водоотдача снижается. Процесс фильтрации бурового раствора в пласт после прекращения циркуляции бурового раствора называется статической водоотдачей [4,34].

Статическая водоотдача является более простым явлением по сравнению с динамической. Как правило, говоря о водоотдаче, подразумевают именно статическую водоотдачу [4]. Методику расчета статической водоотдачи описывается следующим уравнением:

$$V_f = A \sqrt{\frac{K \left(\frac{C_c}{C_m} - 1 \right) \Delta p t}{\mu}}, \quad (1.6)$$

где V_f – объем фильтрата, мл; A – площадь фильтрации, см²; K – проницаемость глинистой корки, л м²; C_c – объемное содержание твердой фазы в глинистой корке, %; C_m – объемное содержание твердой фазы в буровом растворе, %; Δp – перепад давления, 105 Па; t – время фильтрации, с; μ – вязкость фильтрата бурового раствора, мПа·с [4].

Наиболее эффективным способом борьбы с водоотдачей является применение химических агентов, регулирующих проницаемость глинистой корки [27,33].

Статическая водоотдача происходит в отсутствие циркуляции, мешающей нарастанию глинистой корки. Таким образом, если при фильтрации единицы объема устойчивой взвеси твердой фазы в проницаемый субстрат поступит объем фильтрата, равный x , объем глинистой корки (суммарный объем твердой и жидкой фаз), сформированной на поверхности субстрата, будет составлять $1-x$. Следовательно, если Q_c — объем корки, а Q_w — объем фильтрата:

$$\frac{Q_c}{Q_w} = \frac{1-x}{x}, \quad (1.7)$$

то толщина глинистой корки (h) на единицу площади в единицу времени будет составлять:

$$h = \frac{1-x}{x} \cdot Q_w. \quad (1.8)$$

Закон Дарси утверждает:

$$\frac{dq}{dt} = \frac{kP}{\mu h}, \quad (1.9)$$

где k — проницаемость в дарси, P — перепад давления в атмосферах, μ — вязкость фильтрата в сантипуазах, h — толщина в сантиметрах, q — объем фильтрата в кубических сантиметрах, и t — время в секундах.

Таким образом, объединив:

$$\frac{dq}{dt} = \frac{kP}{\mu Q_w} \cdot \frac{x}{1-x}, \quad (1.10)$$

и

$$Q_w^2 = \frac{2kP}{\mu} \cdot \frac{x}{1-x} t, \quad (1.11)$$

получаем:

$$Q_w^2 = \frac{2kPA^2}{\mu} \cdot \frac{Q_w}{Q_c} t. \quad (1.12)$$

Это фундаментальное уравнение, описывающее водоотдачу в статических условиях [1].

- **Зависимость объема водоотдачи от времени**

Ларсен (1938) обнаружил, что при фильтрации бурового раствора через бумагу при постоянной температуре и давлении, значение Q_w пропорционально \sqrt{t} , за исключением небольшой нулевой погрешности [1]. Из этого следует, что для данного раствора значения Q_w/Q_c и k в уравнении (32) с течением времени не меняются. Несмотря на то, что данное утверждение не является абсолютно верным для всех типов буровых растворов, оно достаточно приемлемо для практического применения и формирует основу современной интерпретации механики статической водоотдачи. На рисунке 1.7 показан типичный график кумулятивного объема фильтрата по отношению ко времени, построенный в квадратичной шкале. Точка пересечения с осью Y соответствует нулевой погрешности [35].

Нулевая погрешность, обычно называемая мгновенной фильтрацией, в значительной степени вызвана тенденцией более мелких частиц проходить через фильтровальную бумагу вплоть до закупорки ее пор, после чего через бумагу поступает только фильтрат, и кривая становится линейной. Для большинства буровых растворов нулевая погрешность пренебрежимо низка, но она может быть существенной, когда фильтрация происходит в пористые породы. Некоторые буровые растворы закупоривают фильтровальную бумагу почти мгновенно, в этом случае нулевая погрешность приобретает отрицательное значение и представляет собой объем между бумагой и выходным патрубком. Результаты экспериментов Ларсена показали, что для данного давления уравнение 1.12 может быть записано как

$$Q_w - q_0 = A\sqrt{(C \cdot t)}, \quad (1.13)$$

где q_0 — нулевая погрешность, а C — константа, заданная

$$C = \frac{2kP}{\mu} \cdot \frac{Q_w}{Q_c}, \quad (1.14)$$

Таким образом, водоотдачу различных буровых растворов можно оценить путем измерения объема фильтрата, накапливающегося в стандартное время и в

стандартных условиях. Американский Нефтяной Институт API рекомендует следующие условия [1]:

Время: 30 мин

Давление: 100 фунтов на кв. дюйм (6,8 атмосферы, 7 кг/см²).

Площадь корки: приблизительно 7 кв. дюймов (45 см²).




Рисунок 1.7 – Отношение объема фильтрата к квадратному корню из времени [14].

Объем фильтрата, накапливаемый за 30 мин, можно спрогнозировать на основе объема Q_w , наблюдаемого в момент времени t_1 , в соответствии с уравнением 1.15.

$$Q_{w30} - q_0 = (Q_{w1} - q_0) \cdot \frac{\sqrt{t_{30}}}{t_1}, \quad (1.15)$$

Например, 30—минутный объем фильтрата иногда прогнозируют путем измерения объема фильтрата через 7,5 мин и удвоения полученного значения в соответствии с $\sqrt{30}/\sqrt{7.5} = 2$ [14].

1.2.3. Плотность бурового раствора

Плотность бурового раствора ($\rho_{бр}$)— это масса единицы объема бурового раствора, выраженная в кг/м³ или г/см³. Для предотвращения обрушения стенок скважины и попадания пластового флюида в ствол скважины необходимо создать

достаточное гидростатическое давление [1]. Чем выше плотность бурового раствора по сравнению с плотностью бурового шлама, тем более эффективна промывка ствола скважины, поскольку шлам будет легче удерживаться во взвешенном состоянии. Чрезмерная плотность бурового раствора приводит к снижению скорости проходки, повышению рисков дифференциального прихвата и разрыва породы; кроме того, стоимость такого бурового раствора будет выше. Наиболее распространенным утяжелителем является барит.

1.2.4. Содержание твердой фазы в буровом растворе

Под твердой фазой, как правило, понимаются плотные частицы барита и иных утяжелителей, менее плотные частицы глин, полимеров и тампонажных материалов, добавляемые в буровой раствор при его приготовлении, а также выбуренный шлам. Количество и тип твердой фазы в буровом растворе влияют на ряд его характеристик. Высокое содержание твердых веществ, особенно низкой плотности, увеличивает пластическую вязкость и прочность геля. При высоком содержании твердой фазы в буровом растворе толщина глинистой корки возрастает, а скорость бурения падает [1]. Крупные частицы песка в буровом растворе оказывают абразивное действие на компоненты насосов, трубные изделия, измерительное оборудование и погружные двигатели. Измерение общего содержания твердой фазы традиционно осуществляется с использованием реторты, которая дистиллирует жидкую фазу, позволяя измерить ее объем. В полевых условиях, как правило, замеряется содержание твердых частиц песка размером менее 74 мкм, для чего используется специальная трубка. Это простая и быстрая процедура, которая регулярно практикуется на буровых площадках для мониторинга параметров бурового раствора [1,3–5].

1.2.5. Вязкость бурового раствора, измеряемая с помощью воронки Марша

Условная вязкость (УВ) — это время в секундах, требуемое для протекания одной кварты бурового раствора через воронку емкостью 946 см³. Кварта воды проходит воронку за 26 секунд. Полученное таким образом значение не является истинной вязкостью и служит для качественной оценки вязкости образца, особенно

в сравнении с другими образцами. Однако, благодаря простоте и скорости измерения, оно регулярно (3–4 раза в час) проводится на буровой площадке с целью оперативной оценки свойств бурового раствора [1,3–5].

1.3. Измерение свойств бурового раствора

В полевых условиях работы ведутся в соответствии с заранее составленной картой буровых растворов, свойства которых измеряются в специальных лабораториях, сооружаемых на буровых площадках. Основные проводимые измерения включают определение веса или плотности раствора, ротационную вискозиметрию (например, на приборе FANN35), а также испытания на фильтр–прессе при низком давлении / низкой температуре и высоком давлении / высокой температуре. Вышеперечисленные измерения отнимают много времени и требуют тщательной очистки оборудования после каждого применения. По этой причине полный комплекс измерений свойств бурового раствора в полевых условиях, как правило, выполняется один раз утром и один раз вечером. Менее сложные и затратные рутинные измерения (такие как определение плотности, содержания твердой фазы и условной вязкости) выполняются гораздо чаще (как правило, каждые 15–20 минут) [36]. Однако отсутствие регулярного детального мониторинга реологических и фильтрационных свойств в ходе проведения буровых работ препятствует принятию оперативных решений, необходимых для восстановления свойств промывочных жидкостей. Таким образом возникают риски несвоевременного реагирования на возникающие осложнения, что, в конечном счете, приводит к снижению скорости проходки. В ходе всего цикла буровых работ необходимо регулярно получать информацию относительно всех ключевых параметров буровых растворов [37].

Запрос на измерение свойств бурового раствора в режиме реального времени потенциально может быть удовлетворен с помощью искусственного интеллекта (ИИ) и, в частности, алгоритмов машинного обучения (МО). Вышеупомянутые технологии предлагают экономичные инструменты, способные использовать данные, полученные в ходе рутинных измерений, для прогнозирования более

сложных и затратных в измерении переменных, представляющих высокую ценность. Производительность алгоритмов МО может различаться в зависимости от условий задачи. Признание проблемы, а также полное понимание производительности алгоритмов МО при разработке прогностических моделей может гарантировать построение модели с высокой точностью и обобщающей способностью. В этой связи далее рассматриваются понятия, связанные с алгоритмами МО, а также их применение в добывающей нефтегазовой промышленности.

1.4. Краткое введение в машинное обучение

Машинное обучение (МО)— это область, где компьютеры алгоритмически запрограммированы не на прямое решение задачи, а на обучение и адаптацию на основе получаемого опыта с целью повышения эффективности решения задачи, измеряемой с использованием метрики. Это определение можно проиллюстрировать примером задачи, в которой целью является распознавание рукописных цифр, а метрикой является процент цифр, правильно распознанных с использованием размеченной человеком базы изображений рукописных цифр, используемой в качестве источника опыта [38]. «Обучающаяся» часть использует большие объемы данных, чтобы компьютер умел понимать основные закономерности. Благодаря росту вычислительной мощности и производительности машин за последние несколько лет произошло значительное повышение эффективности алгоритмов МО. Области, в которых успешно применяется МО, включают в себя распознавание изображений, текстовый анализ (например, для обучения спам-фильтров), анализ эмоциональной окраски высказываний, извлечение информации, производство видеоигр, робототехнику, и этот список постоянно пополняется [39].

1.4.1. Основные концепции машинного обучения

Термины «машинное обучение» и «искусственный интеллект» часто употребляются как взаимозаменяемые. Фактически же несмотря на то, что эти два термина описывают разные концепции, хотя искусственный интеллект является

понятием более общего характера, в которое входит и понятие МО. Так как, МО это совокупное название разнообразных методов, направленных на создание моделей на основе достаточного количества эмпирических данных. Они не требуют использования физических законов или спецификаций характеристик машины. Они определяют взаимозависимость переменных, используя данные и только данные [39,40].

Это не означает, что потребность в эксперте–человеке перестала существовать. Эксперт–человек по–прежнему важен, однако природа его экспертизы существенно отличается от модели на основе первых принципов. В машинном обучении экспертные знания в предметной области предоставляются главным образом следующими четырьмя способами [39]:

1. Предоставление всех релевантных переменных и исключение всех нерелевантных переменных. Сюда могут входить и переменные, подвергнутые элементарной обработке с помощью конструирования признаков – например, если нам известно, что отношение одной переменной к другой имеет высокую важность, мы можем захотеть явно указать это отношение в виде отдельного столбца в таблице данных.
2. Предоставление эмпирических данных, которые являются значимыми и репрезентативными для ситуации.
3. Оценка результатов моделей–кандидатов, чтобы убедиться, что они совпадают с ожидаемыми.
4. Явное добавление любых существенных ограничений, которые должны соблюдаться.

Эти методы предоставления экспертизы важны, однако они принципиально не отличаются от работы эксперта–человека, который хорошо разбирается в предметной области и мало знает о теории и методах анализа данных [39,40].

В целом, процесс МО подразделяется на три основных компонента. Первый — это построение прототипных моделей, которые могут применяться к имеющимся данным. Это могут быть нейронные сети, деревья решений или кластеризация методом k –средних. Далее, каждая модель сопровождается рядом

предписаний – то есть, алгоритмов расчета коэффициентов модели на основании наборов данных. Такие расчеты также называются обучением модели. После обучения первоначальный прототип превращается в модель для конкретного предоставленного набора данных. И затем, чтобы модель можно было использовать, ее необходимо развернуть. Как правило, модель гораздо проще и быстрее оценить, чем обучить. Это одна из основных особенностей МО, которые делают его столь привлекательным: обученную модель можно использовать в режиме реального времени. Однако для полного раскрытия потенциала модель должна быть встроена в правильную инфраструктуру [39].

С машинным обучением связаны две важные темы, которые лежат в основе науки о данных. Во-первых, данные должны быть надлежащим образом подготовлены к обучению, что освещается в главе 2 настоящего исследования. Во-вторых, результирующая модель должна быть надлежащим образом верифицирована, а ее производительность должна быть продемонстрирована с использованием строгих математических методов. Пред- и постобработка до и после МО являются частью научной составляющей проектов по обработке и анализу данных. Помимо научной, присутствуют также управленческие и организационные составляющие, связанные со сбором данных и работой с заинтересованными сторонами [39,40].

1.4.2. Методы машинного обучения

Методы МО часто делятся на две группы на основе двух разных атрибутов. Один атрибут подразумевает разделение методов на ***контролируемые*** и ***неконтролируемые***. Другой атрибут подразумевает разделение методов МО на методы ***классификации*** и ***регрессии***, определяемые на основе типа решаемой задачи [40,41].

Контролируемые методы имеют дело с наборами данных, для которых мы обладаем эмпирической информацией, используемой в качестве как входных данных модели, так и желаемых результатов моделирования. Неконтролируемые методы имеют дело с наборами данных, для которых у нас есть только входная

информация. Представьте себе, что вы учите ребенка складывать два числа. Контролируемое обучение будет состоять из таких примеров, как $1 + 2 = 3$ и $5 + 4 = 9$, тогда как неконтролируемое обучение – только из таких примеров, как $1 + 2$ и $5 + 4$. Из этого примера видно, от контролируемых методов ожидается более высокая точность в воспроизведении результата. От неконтролируемых методов ожидается, что они изучат структуру входных данных и распознают в них некоторые закономерности. Рисунок 1.8 иллюстрирует разницу в контексте изучения на примере двух наборов точек данных [39,40].




Рисунок 1.8 – Иллюстрация разницы между контролируемым и неконтролируемым обучением [39].

Из примера, приведенного на рисунке 1.8, мы видим, что круги и треугольники классифицируются как различные объекты, и задачей обучения является правильное разделение пространства. Однако во втором примере присутствуют только точки; таким образом, задачей обучения является их осмысленное разделение на два кластера таким образом, чтобы точки в одном кластере были максимально похожими, а точки в разных кластерах максимально отличались бы друг от друга – в той степени, которая будет иметь смысл в контексте заданной предметной области [40].

Разница между методами классификации и регрессии также является фундаментальной. Методы классификации направлены на то, чтобы поместить точку данных в одну из нескольких групп, в то время как методы регрессии

направлены на вычисление некоторого числового значения. Рисунок 1.9 иллюстрирует разницу между этими методами. В первом примере мы хотим только провести линию, отделяющую круги от треугольников. Во втором примере мы хотим максимально точно воспроизвести непрерывное числовое значение [39].




Рисунок 1.9 – Иллюстрация разницы между методами классификации и регрессии [39].

МО включает в себя множество методов, и все методы являются либо контролируруемыми, либо неконтролируемыми, а также являются методами классификации либо регрессии. Любая задача из любой области науки и техники, решаемая методами МО, также может быть описана в вышеуказанных категориях [42]. Ниже кратко рассматриваются некоторые из современных примеров применения методов МО в различных областях разведки и разработки месторождений нефти и газа, включая поиск подземных или подводных залежей, бурение разведочных скважин, а также строительство и эксплуатацию добывающих скважин. Следует отметить, что разведка и добыча представляют особый интерес, так как являются наиболее капиталоемкими и важными областями нефтегазового бизнеса [39].

1.5. Применение машинного обучения в разведке и разработке месторождений нефти и газа

В настоящем разделе описывается применение методов МО в нефтегазовой промышленности с акцентом на инженерию буровых растворов.

1.5.1. Машинное обучение в разведке месторождений нефти и газа

Разведка месторождений углеводородов сопряжена со значительными рисками. Геологоразведчикам необходимо точно определить перспективные цели для поискового бурения и разработки. В начале 21-го века предпринимались попытки определения целей бурения на основе картирования недр и ограниченных данных сейсморазведки 2D. В силу значительных рисков вероятность успеха составляла 1:7. В ходе изучения лицензионных участков для каждого из них в значительных объемах аккумулировались результаты сбора, обработки и интерпретации сейсмических и скважинных данных, для хранения которых требовались терабайты дискового пространства. Они получили название «больших данных», которые анализируются с помощью методов МО. Целью использования больших данных в машинном обучении является улучшение соотношения «сигнал/шум» во время сбора и обработки. Полученные чистые данные используются для интерпретации результатов сейсморазведки 2D, 3D и 4D с использованием надежных алгоритмов. Точное картирование подземных горизонтов помогает интерпретаторам готовить карты объемов залежей и преобразовывать их в карты амплитуды, пористости и насыщенности путем интеграции с данными ГИС. Для более точного понимания геологических данных используются методы инверсии [43,44]. В ходе развития алгоритмов МО стало возможным использовать их для создания атрибутов горизонтов и окон с целью выявления наиболее перспективных объектов. Современные атрибуты, такие как когерентность, краевая карта, спектральная декомпозиция, карта рельефа, являются результатами МО. Понимание полигонов разломов, картирование сложных структур разломов и картирование фаций с использованием седиментационных срезов существенно повысили изученность перспективных объектов. Использование алгоритмов МО для подготовки перспективных участков под бурение позволило повысить вероятность успеха до 1:3. Использование сейсморазведки 4D (т.н. сейсмомониторинга) дает интерпретатору сведения о движении углеводородов после буровых работ [42]. В настоящее время для уточнения целевых перспектив, их размеров и объема углеводородов широко

применяются искусственные нейронные сети (ANNs) и эвристические методы (рисунок 1.10). Такие методы, как моделирование Монте–Карло и эволюционное программирование, используются для получения стохастических диапазонов геологических и извлекаемых запасов углеводородов. В целом, можно уверенно утверждать, что применение методов МО привело к изменению парадигмы разведки и разработки месторождений углеводородов во всем мире [45].

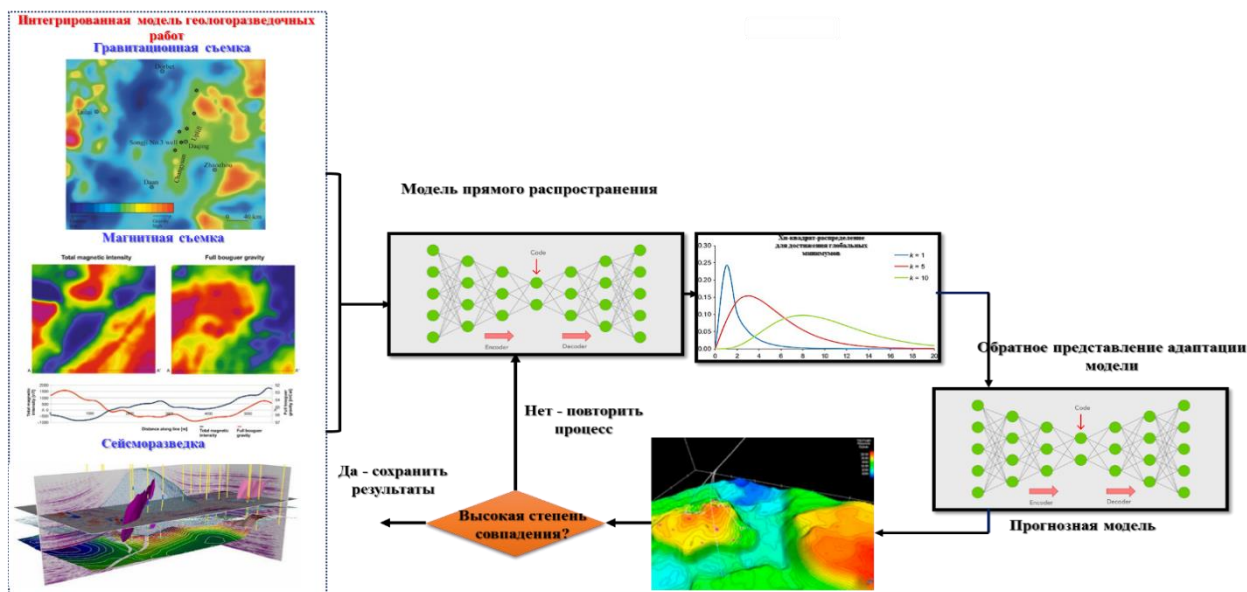


Рисунок 1.10 – Схематическое представление процессов обработки и интерпретации данных при использовании методов МО [46].

Разработчиками создан ряд реалистичных прикладных технологий разведки и разработки месторождений с использованием алгоритмов ИИ. В области геологоразведки использование ANN уже принесло положительные результаты с точки зрения снижения геологических рисков и повышения коэффициента успешности разведочных скважин [47]. Применение современного бурового оборудования, такого как автоматизированные буровые установки и интеллектуальные бурильные трубы, привело к существенному улучшению качества бурения и снижению затрат [48]. Основной областью применения технологий ИИ в разработке нефтяных месторождений является уточнение плана разработки на основе исторических данных по добыче.

При планировании разработки месторождения и ковра бурения могут применяться регрессионные модели. Для характеристики данных применяется

неконтролируемое обучение. В частности, в 2019 году Кумар [42] предложил модель, способную обрабатывать большие данные, которая показала эффективность при изучении сланцев. Задачи физики горных пород могут быть решены методом линеаризованной инверсии. Такая модель способна обеспечивать точные физические параметры, но менее полезна в случаях с высокой степенью не линеаризации [42]. Для получения синтетических скважинных данных из существующих данных ГИС предлагается использовать рекуррентную нейронную сеть. В 2018 году Чжан пришел к выводу, что данный метод МО способен обеспечивать точную и экономичную генерацию каротажных данных [43]. Метод сдвига окна способен обеспечивать более качественное прогнозирование давления по сравнению с методом долгосрочной кратковременной памяти (LSTM) [49]. Дирсен в 2011 году использовал ИИ для сокращения человеческих усилий по обработке и анализу полномолновой сейсмической томографии. Это осуществляется путем интеграции ИИ и комплексного вейвлет–преобразования (CWT). CWT — это вейвлет–преобразование, которое помогает изучать временно–частотные домены осциллограмм. ANN и основанные на знаниях ANNs могут быть использованы для выбора качественных фрагментов сейсмического окна внутри алгоритма полномолновой томографии (рисунок 1.11) [50]. Некоторые современные достижения в области использования МО в геологоразведке приведены в таблице 1.1.

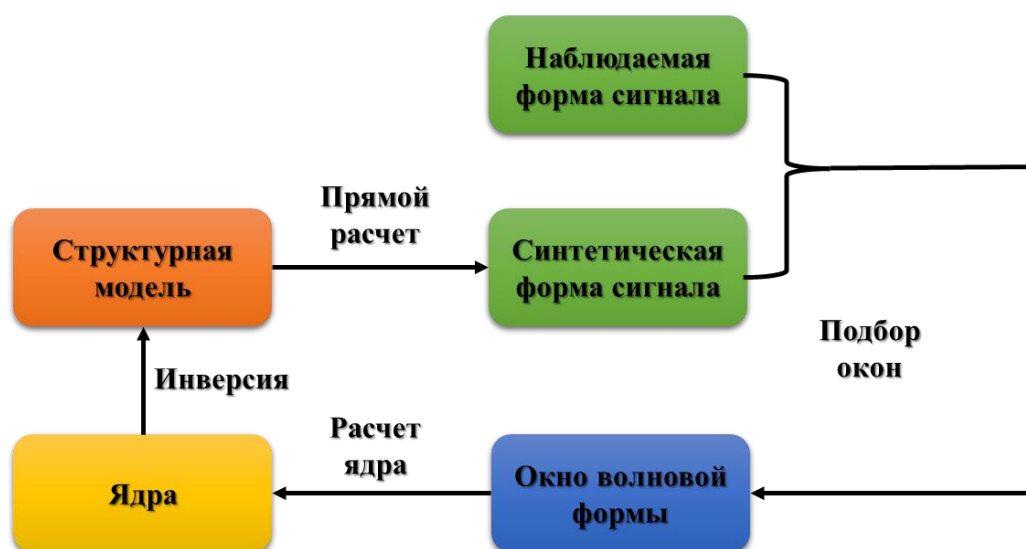


Рисунок 1.11 – Схематическое изображение процесса полномолновой томографии.

Таблица 1.1 – Применение методов МО в геологоразведке

Оптический метод	Область применения	Метод	Источник
ANN	Подбор буровых долот	Декодирование данных в пользовательской информационной базе и изучение кодов для выбора оптимального долота под конкретные условия	[51]
Обобщенно–регрессионная нейронная сеть,	Прогнозирование градиента давления гидроразрыва	Использование данных о глубине, коэффициента Пуассона и градиента горного давления для построения прогнозного графика градиента давления гидроразрыва породы, вызванного давлением бурового раствора	[52]
Нейронная сеть с обучением по методу обратного распространения ошибки	Прогнозирование обрушения обсадной колонны и определение глубины обрушения	Обратное моделирование заданного пользовательской сетью количества внутренних скрытых слоев, соединенных с входным и выходным слоями	[53]
Спектры диффузного отражения с Фурье–преобразованием, ANN	Прогнозирование эффективности нефтепромысловых цементных растворов	Генерация инфракрасного спектра цементного порошка для получения более точной информации о природе цемента	[51]
ANN с обучением по методу обратного распространения ошибки	Выбор морской платформы	Нелинейные нейронные сети с несколькими входными узлами, подготавливающим скрытым слоем и функциями модели, используемыми для выбора глубоководной плавучей платформы	[51]
ANN, Нейронная сеть с обучением по методу обратного распространения ошибки	Точное прогнозирование сопротивления трения	Полноценным образом подготовленная двухслойная нейронная сеть с обучением по методу обратного распространения ошибки используется для определения усилия контакта на забое и сопротивления трения в зависимости от различных параметров упругости	[54]
Нейронная сеть с обучением по методу обратного распространения ошибки	Прогнозирование промывки ствола скважины	Позволяет предотвращать повреждения пласта, стабилизатора и буровых долот в ходе бурения.	[55]

ANN	Повышение скорости проходки	Управление параметрами команд в режиме реального времени для минимизации износа долота при максимизации скорости бурения	[56]
ANN	Оперативное устранение неисправностей	Прогнозирование риска прихвата трубы при проектировании скважины и в режиме реального времени в ходе бурения	[51]
Рассуждения на основе прецедентов	Принятие процедурных решений	Помощь в выборе оптимальной процедуры промывки ствола скважины в рыхлых песчаниках, залегающих на небольших глубинах	[51]

*все аббревиатуры можно найти в номенклатуре

1.5.2. Машинное обучение в технологиях добычи нефти и газа

Передовые методы МО создают новые рабочие процессы, снижающие нагрузку на инженеров. Существует ряд областей применения МО в добыче нефти и газа. Одной из сложнейших задач является анализ больших данных для принятия решений в сжатые сроки. Методы МО могут использоваться для распознавания закономерностей в данных по добыче [57]. Субрахманья в 2015 году использовал технологию активного обучения для получения точек данных с максимальной информационной ценностью. Скважинные данные были объединены с данными из маркированных и немаркированных источников с полуконтролируемым обучением [58]. Данные проверялись, верифицировались и восстанавливались с помощью алгоритмов. Исследователем были проведены корректирующий анализ данных ГИС, контроль качества физико–химических свойств флюидов и разделение между базовой добычей и приростом добычи в результате ВСП [50]. Еще одним важным примером применения МО в нефтегазовом секторе является практика непрерывной интеграции/непрерывного развертывания (CI/CD) (рис. 1.12). Усовершенствованная практика CI/CD должна включать в себя точный и воспроизводимый конвейер МО с механизмами отслеживания, преемственностью и контролем версий. Это особенно полезно для выявления концептуального дрейфа, когда производительность статистической модели со временем

ухудшается из-за изменений в данных и отношениях ввода–вывода, смоделированных ранее [59].

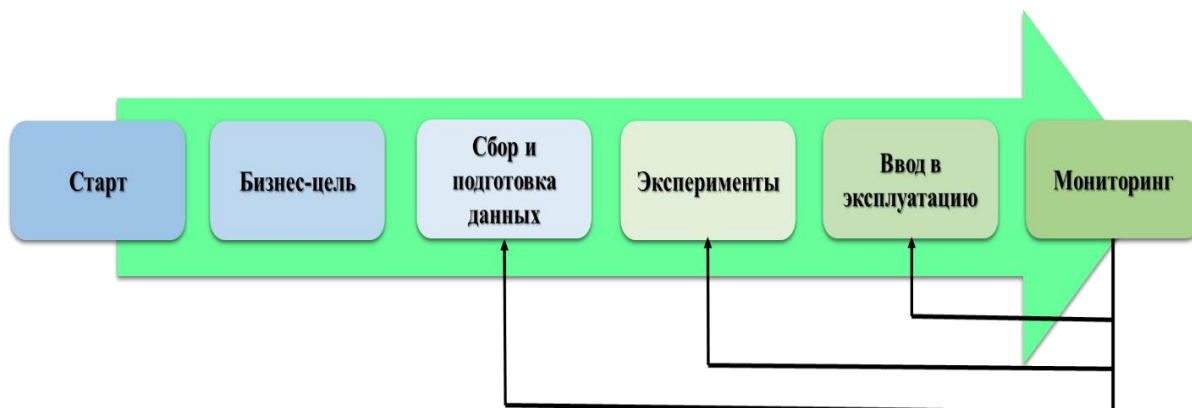


Рисунок 1.12 – Схематическое изображение процесса CI/CD в современном машинном обучении [57]

Большинство морских установок уже превысили свой срок службы. Снижение производительности в данном случае не является единственной проблемой; также повышаются угрозы социальной безопасности и окружающей среде. Одной из возможностей является их деактивация с потерей текущей добычи нефти и газа, либо требуются значительные инвестиции в модернизацию и переоснащение морских платформ. В морском энергетическом секторе уже давно используются цифровые двойники или цифровые копии систем для мониторинга состояния материальных активов, таких как трубопроводы, буры, клапаны и другое оборудование. Эксперты могут прогнозировать поведение системы и выявлять ее потребность в техническом обслуживании, что значительно продлевает их рабочий ресурс [45]. Тем не менее, подобные симуляции довольно статичны, поскольку не учитывают все изменения в реальных физических условиях, которые могут повлиять на производительность актива с течением времени. Новые методы контроля позволяют загружать данные с промышленных датчиков о фактических воздействиях внешней среды на актив в его цифровую копию. Некоторые из исследований, проведенных с помощью алгоритмов МО в нефтегазовой отрасли, перечислены в таблице 1.2.

Таблица 1.2 – Применение методов МО для решения производственных проблем в нефтегазовой отрасли.

Метод	Входные параметры	Выходные параметры	Источник
ANN и адаптивная сетевая система нечеткого вывода	Кавернометрия, пористость, ГК, плотность, нейтронный каротаж, резистивиметрия	Водонасыщенность	[60]
Многослойная перцептронная нейронная сеть	Продолжительность работы скважины, распределенные измерения температуры, распределенные акустические измерения	Добыча газа	[61]
Обратное распространение	ГК, нейтронный каротаж, плотностной каротаж, акустический каротаж, глубинная резистивиметрия	Пористость; проницаемость	[62]
ANN	Горизонтальная проницаемость, пористость, скорость	Добыча нефти	[63]
Групповой метод обработки данных (GMDH), полиномиальная регрессия	Неснижаемая водонасыщенность, удельная площадь поверхности пор, пористость	Проницаемость	[64]
Многослойная экстремальная обучающая машина (MELM), оптимизированная оптимизатором роя частиц (PSO)	Температура (Т), давление вверх по течению (P _u), давление вниз по течению (P _d), удельная плотность газа (γ_g), диаметр дросселя (D ₆₄), газожидкостный фактор (GLR)	Дебит газа	[34]
Сверточная нейронная сеть (CNN)	Температура жидкости (T _f), давление вверх по течению (P _u), корень квадратный из дифференциального давления ($\sqrt{\Delta P}$), общее содержание мехпримесей и воды (BS&W%), удельная плотность нефти (SG), кинематическая вязкость (ν), относительный диаметр (β , отношение диаметра трубы к диаметру отверстия).	Дебит нефти	[65]
Случайный лес (RF)	Диаметр дросселя (D ₆₄), устьевое давление скважины (P _{wh}), удельная плотность нефти (γ_o), газожидкостный фактор (GLR)	Дебит двухфазной жидкости	[66]
Многослойный перцептрон, оптимизированный светлячком (FF)	Температура вверх по течению (Т), давление вверх по течению (P), удельная плотность нефти (SG), общее содержание мехпримесей и воды (BS&W%), кинематическая вязкость (ν), относительный диаметр (β , отношение диаметра трубы к диаметру отверстия), корень квадратный из дифференциального давления ($\sqrt{\Delta P}$)	Дебит нефти	[67]

Адаптивная нейро- нечеткая система вывода Такаги- Сугено (TSFIS)	Давление вверх по течению (Pwh); диаметр устьевого дросселя (D64), газожидкостный фактор (GLR), общее содержание мехпримесей и воды, включая некоторые водорастворимые нефтяные эмульсии (BS&W%)	Многофазный дебит	[68]
---	---	----------------------	------

1.5.3. Машинное обучение в разработке месторождений нефти и газа

Разработка месторождений связана с гидродинамическими расчетами потока флюида в пористой среде, прогнозированием добычи и оптимизацией эксплуатации месторождений. Для построения карт свойств горных пород и осуществления PVT-анализа необходимо построение численных моделей. При построении статических и динамических моделей используются значительные объемы данных: результаты сейсморазведки, геофизических исследований скважин, анализа керна, а также история добычи интегрируются с использованием алгоритмов МО для разработки проектов доразведки и разработки месторождений. Комплексный анализ неустановившегося давления и деконволюция данных по давлению проводятся с использованием ANN, генетических алгоритмов, моделей поверхности отклика и других алгоритмов. Генетические алгоритмы эффективны при адаптации моделей и подготовки профилей добычи P90, P50 и P10. Значительные объемы данных используются для подготовки карт коллекторов, которые итеративно дополняются при обновлениях базы данных. ANN используются для оценки фильтрационно-емкостных свойств: пористости и проницаемости. Задачи, связанные с прогнозированием свойств пластового флюида, могут решаться путем применения различных методов МО, таких как методы k-ближайших соседей, регрессии опорных векторов, регрессии ядра, адаптивного улучшения и совместной фильтрации. Онвучеква [69] установил, что метод совместной фильтрации, изначально разработанный для системы рекомендаций потребительских товаров, может эффективно использоваться при разработке месторождений. Для численного моделирования могут быть использованы синтетические гидродинамические модели. Далее, Тейшейра и

Секки [70] использовали алгоритм оптимизации для определения оптимального режима разработки с целью максимизации общей добычи нефти. Сравнивая различные методы МО, можно провести параметрические исследования для прогнозирования проницаемости, сейсмических атрибутов и данных ГИС. Производительность метода опорных векторов превышает производительность других методов МО при прогнозировании проницаемости. Анифозе [71] методом экстремального градиентного бустинга (XGBoost) построил интеллектуальную модель для прогнозирования отклика коллектора на работу скважин ППД. Нвачукву [72] отобрал ряд сценариев, таких как равномерное заводнение пласта, направленное заводнение пласта, комплексное заводнение по 20 реализациям модели, а также закачку двуокиси углерода (CO_2) в неоднородный коллектор со сложной топографией. На рисунке 1.13 представлена процедура адаптации гидродинамической модели с помощью алгоритмов ИИ для настройки фильтрационно–емкостных свойств [72].

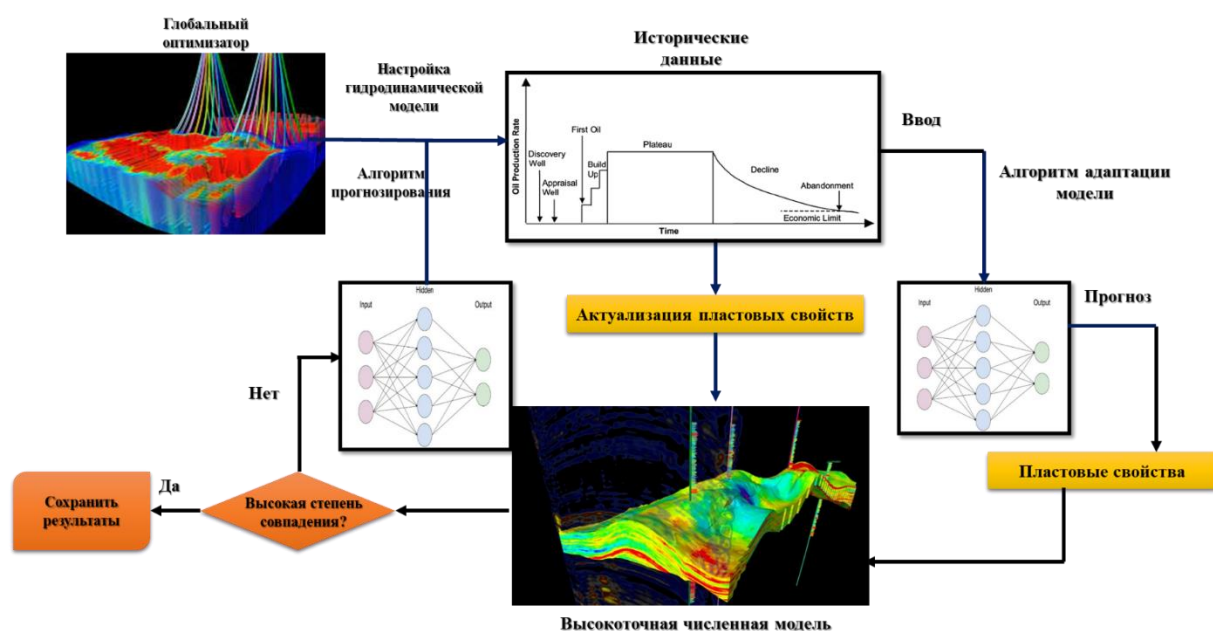


Рисунок 1.13 – Схематическое изображение процесса построения гидродинамической модели с использованием искусственной нейронной сети [73].

Некоторые примеры исследования применения ИИ в разработке месторождений нефти и газа перечислены в таблице 1.3.

Таблица 1.3 – Применение методов МО при разработке месторождений нефти и газа

Метод	Входные параметры	Выходные параметры	Источник
Машина экстремального обучения с многочисленными скрытыми слоями, оптимизированная с помощью генетического алгоритма.	Температура (Т), газовый фактор пластовой нефти (Rs), удельная плотность газа (γ_g), плотность нефти (API)	Давление насыщения	[74]
Дерево решений регрессии	Боковой каротаж малым зондом, ГК с учетом поправок, скорость поперечной волны (V_s), спектрометрический ГК, объемная плотность (RHOV), коэффициент фотоэлектрического поглощения (PEF), пористость по нейтронному каротажу, удельное сопротивление в дальней части пласта, скорость продольной волны (V_p)	Поровое давление	[75]
Машина экстремального обучения с многочисленными скрытыми слоями, оптимизированная с помощью генетического алгоритма и алгоритма оптимизации методом роя частиц	Давление (P), температура (T), начальный газоконденсатный фактор (RS), удельная плотность газа (γ_g), удельная плотность конденсата (API)	Вязкость конденсата	[76]
Искусственные нейронные сети	Глубина отбора керна, кавернометрия, ГК, плотность по нейтронному каротажу, акустический каротаж	Плотность трещин гидроразрыва	[77]
Групповой метод обработки данных	Растворимость газа, пластовая температура, плотность нефти в градусах API, удельная плотность газа	Объемный коэффициент нефти	[78]
Многослойный перцептрон (MLP) с оптимизатором	Данные геофизических исследований скважин	Плотность трещин в пласте	[79]
Многослойная машина экстремального обучения (MELM), оптимизированная с помощью методов глобальной оптимизации	Данные геофизических исследований скважин	Проницаемость	[80]

1.5.4. Машинное обучение в буровом деле

Ряд методов МО может внедряться для смягчения различных осложнений, возникающих при бурении, и содействия в разработке экономически эффективных решений [38]. Далее приводятся некоторые примеры применения алгоритмов МО для решения задач, связанных с различными аспектами бурового дела, а именно: гидравликой бурения, прогнозированием давления, потерями давления и транспортом бурового шлама.

Гидравлика бурения

Под гидравликой бурения понимается характер циркуляции бурового раствора в стволе скважины, то есть, преимущественно гидромеханика бурового раствора. Предполагается, что в стволе скважины создается высокое давление, особенно в случаях бурения на большие глубины. Понимание гидравлики бурения имеет важное значение, поскольку оно связано со следующими предметными областями: (1) определением безопасного давления бурения (в целях предотвращения обрушения стенок ствола или формирования трещин растяжения); (2) выбором диаметра струйной насадки долота; (3) поршневанием и свабированием в ходе спуско–подъемных операций; 4) продавкой цемента; и 5) транспортом бурового шлама. В зависимости от условий, гидравлическое поведение бурового раствора может начинаться с простого ламинарного потока ньютоновской жидкости в идеально вертикальном стволе скважины и развиваться до сложного турбулентного потока неньютоновской жидкости в наклонно–направленных или горизонтальных скважинах [81].

Применение алгоритмов МО в области гидравлики бурения концентрируется на двух основных направлениях: прогнозирование давления (в определенной точке или на определенном интервале) и транспортировка бурового шлама. Поскольку в данном случае речь идет о гидромеханике, наиболее распространенными входными данными являются параметры бурового раствора (реологические свойства и скорость циркуляции). Другие входные данные включают параметры бурения (скорость проходки, частота вращения, крутящий момент и т. д.) и свойства выбуренных частиц (концентрация / плотность). В данной области наиболее часто

используются искусственные нейронные сети, но находят применение и другие методы, такие как метод случайного леса, метод опорных векторов и генетические алгоритмы. В модели использовался крупный набор данных из 53000 записей в виде временной последовательности.

Прогнозирование давления

В данном случае подразумеваются давление на насосе и давление в напорной линии. Фрухвирт разработал метод прогнозирования давления на насосе на основе преимущественно параметров бурения [82]. В его первой модели в качестве исходных данных используются стандартные параметры бурения, такие как скорость проходки, частота вращения и крутящий момент. В последующие модели включены также свойства жидкости (число Рейнольдса) и дополнительная информация о скважине (наклон и азимут ствола, измеренная глубина, интенсивность искривления ствола и т. д.). В результате производительность модели была повышена более чем на 50% по среднеквадратичного отклонения, то есть, погрешность в прогнозировании давления составляла 2 бара (29 фунтов на кв. дюйм) [82]. Ван и Салехи использовали аналогичные входные данные (глубина и параметры бурения) для прогнозирования давления на насосе. Были использованы данные из 3 скважин и достигнут высокий коэффициент детерминации (R^2) 0,9981 при прогнозировании скорости проходки. Однако прогноз давления, несмотря на высокое качество адаптации, не удалось выразить количественно [83]. Эрге и ван Оорт разработали гибридную модель, сочетающую физическое и управляемое данными моделирование со стохастическим алгоритмом принятия решений на основе правил для прогнозирования давления в напорной линии. Сначала было представлено несколько традиционных физических моделей. Как модели на основе МО, так и гибридная модель продемонстрировали более высокую эффективность по сравнению с моделью, основанной на физике, при этом гибридная модель показала наилучшие результаты со снижением среднеквадратичного отклонения (RMSE) до 22% по сравнению с моделями на основе МО [84].

Потери давления

Прогнозирование потери давления на определенном интервале важно как в буровом деле, так и в добыче углеводородов. Помимо свойств жидкости, в качестве входных данных обычно используются свойства трубы или скважины, такие как отношение диаметра трубы к обсадной колонне, наклон ствола, эксцентricность кольцевого зазора и т.д. Руки использовал искусственную нейронную сеть для прогнозирования потери давления бурового раствора типа Гершеля–Балкли по экспериментальным данным. Были достигнуты отличные результаты (коэффициент корреляции $R > 0.99$, средняя абсолютная ошибка 4,32%). В частности, рассматривается влияние эксцентricности бурильной трубы на потерю давления. Разработанная на основе искусственной нейронной сети модель способна повысить эффективность транспорта шлама / промывки ствола скважины, особенно в наклонно–направленных и горизонтальных стволах [85]. Али использовал искусственную нейронную сеть с генетическим алгоритмом для прогнозирования потери давления в кольцевом зазоре наклонно–направленной скважины при бурении на депрессии. Рассматривался сценарий многофазного потока (газ и жидкость), и качество результатов было высоким ($R^2 = 0.99$) [86]. Озбайоглу использовал искусственную нейронную сеть для прогнозирования потерь давления при изгибе бурильной колонны во время вращения. Данные были получены на экспериментальной установке с функцией изгиба, и была достигнута средняя абсолютная ошибка 5%. В вышеупомянутом исследовании также продемонстрировано, что модель с результатами непосредственных измерений в качестве входных данных показывает более высокую эффективность, чем модель с безразмерными данными на входе. В целях оптимизации добычи был разработан ряд механистических моделей многофазного потока (нефть, газ и вода). Однако при бурении в циркулирующем потоке также присутствует буровой шлам, поэтому твердую фазу также следует принимать во внимание. С другой стороны, модели, изначально разработанные для бурения, могут быть использованы и при оптимизации добычи. Несмотря на то, что существуют некоторые аналитические решения с упрощенными условиями, алгоритмы, основанные на машинном

обучении, более эффективно моделируют ряд более сложных условий (изгиб, присутствие твердой фазы, вращение и т.д.).

Транспортировка бурового шлама

Еще одной областью применения алгоритмов МО в буровом деле является оптимизация промывки ствола скважины (т.е., транспортировки шлама). Исследования в данной области анализируют либо концентрацию твердых частиц или высоту шламовой подушки, либо характеристики потока (например, коэффициент трения). Для изучения концентрации шлама Озбайоглу использовал искусственную нейронную сеть, прогнозирующую высоту шламовой подушки. Важным входным параметром также является концентрация шлама на буровом долоте. Другие входные данные включают в себя безразмерные переменные, выведенные из основных параметров бурения (мощность насоса, плотность и вязкость бурового раствора, скорость проходки и геометрия ствола скважины) [87]. Коэффициент погрешности данной модели составляет менее 10%. Руки использовал искусственную нейронную сеть и алгоритмы множественной линейной регрессии для прогнозирования концентрации шлама при бурении на пенообразном буровом растворе на основе экспериментальных данных. Во входные данные включены свойства пены (скорость течения и качество).

Свойства шлама (такие, как размер и плотность) в силу своего постоянного характера были исключены из входных данных. Таким образом, сфера применения результатов данного исследования ограничена конкретными свойствами бурового шлама [55]. ANN показала самую высокую точность (средняя абсолютная ошибка 3,2%) по сравнению с моделью множественной линейной регрессии и механистической моделью. Камьяб разработал новую модель на основе искусственной нейронной сети для определения скорости осаждения обломков выбуренной породы в вертикальной скважине. Используются следующие входные данные: число Рейнольдса и сферичность частицы. Количественные показатели модели не приводятся, но качественно прогнозируемые результаты хорошо согласуются с эмпирическими соотношениями [88].

В настоящее время исследуется регрессионная задача, связанная с прогнозированием трех важных свойств бурового раствора [81]. В следующем разделе настоящего исследования основное внимание будет уделено моделям МО, разработанным для прогнозирования трех целевых параметров буровых растворов.

Таблица 1.4 – Применение методов МО в буровом деле

Метод	Входные параметры	Выходные параметры	Источник
Многослойный перцептрон	Глубина, удельное сопротивление пласта (RT), статический модуль Юнга (E), минимальное горизонтальное напряжение (Sh), диаметр долота (BS), эквивалентная плотность циркуляции (ECD), нагрузка на долото (WOB), частота вращения (RPM) и расход на насосе (FPR)	Скорость проходки	[89]
Сверточная нейронная сеть (CNN)	Давление на насосе, плотность бурового раствора, давление разрыва породы, поровое давление, глубина, статическое напряжение сдвига через 10 минут/секунд покоя, вязкость при 600/300 оборотах вискозиметра, расход бурового раствора и тип пласта	Темп поглощения бурового раствора	[90]
ANN	Параметры бурового раствора: плотность и реологические характеристики (пластическая вязкость и динамическое напряжение сдвига) Параметры бурения: Угол наклона ствола, эксцентricность трубы (т.е. отход оси бурильной трубы от оси ствола скважины), скорость проходки (ROP), расход бурового раствора (GPM), скорость вращения бурильной трубы (RPM) и температура.	Концентрация шлама в буровом растворе	[91]
Машина опорных векторов	Соотношение диаметров (D_i/D_o), показатель текучести (n), эксцентricность кольцевого зазора (e), коэффициент консистентности (k), предел текучести и расход (Q).	Потери давления в жидкости типа Гершеля–Балкли	[92]
Рекуррентная нейронная сеть с долговременной и кратковременной памятью (LSTM–RNN)	Давление в напорной линии и тренд наклона d–экспоненты	Выявление ГНВП в ходе бурения	[93]
Многослойная машина экстремального обучения (MELM), оптимизированная с помощью методов глобальной оптимизации	Плотность бурового раствора, условная вязкость и содержания твердой фазы	водоотдача, пластическая вязкость и динамическое напряжение сдвига	[94]

Метод опорных векторов с наименьшими квадратами (LSSVM), оснащенный глобальным оптимизатором	Данные геофизических исследований скважин	Механическая хрупкость горных пород	[95]
--	---	-------------------------------------	------

1.6. Исторический обзор исследований в области прогнозирования свойств бурового раствора

В течение последнего десятилетия методы МО нашли свое применение в технологиях буровых растворов, в частности, при прогнозировании реологических свойств, плотности, поглощения раствора пластом и водоотдачи [81,96,97]. Поскольку настоящее диссертационное исследование посвящено разработке и внедрению гибридных моделей МО для прогнозирования свойств бурового раствора, мы провели комплексный, систематический и критический обзор существующих публикаций, посвященных применению алгоритмов МО для прогнозирования наших целевых параметров [38,81]. Подобный критический обзор не только способствует пониманию современных достижений в моделировании свойств бурового раствора на основе МО, но и выявляет недостатки, ограничения и проблемы, не решенные в существующих публикациях [38]. Еще одной задачей обзора публикаций является отражение задач, актуальности и научной новизны настоящего диссертационного исследования.

Первая интеллектуальная модель для прогнозирования реологических свойств определенного типа бурового раствора на водной основе была предложена в 2016 году [98]. В данном исследовании применялась модель, основанная на искусственной нейронной сети, и предназначенная для прогнозирования реологических свойств инвертно-эмульсионного бурового раствора на нефтяной основе. В качестве входных данных использовались 9000 измеренных в полевых условиях значений условной вязкости, плотности и концентрации твердой фазы. Представленные результаты показали, что модель, основанная на искусственной

нейронной сети, была способна прогнозировать четыре реологических параметра, а именно, ПВ, ДНС, показатель текучести (n) и консистентность (k), с относительно высокой точностью (абсолютная процентная погрешность (APE) = 3,7–5%; $R^2 = 0,89–0,92$) [98]. Несмотря на высокую прогнозную эффективность разработанной модели, она могла быть применима только к одному типу бурового раствора: инвертно–эмульсионному буровому раствору [38].

Алсабаа и др. [99] применили адаптивную сеть на основе системы нечёткого вывода к 741 записи данных по инвертно–эмульсионным буровым растворам для прогнозирования реологических свойств (ДНС, ПВ, n и K) с использованием двух входных параметров: условной вязкости и плотности. Результаты их исследования показали, что адаптивная сеть на основе системы нечёткого вывода достигает точности прогнозирования, сопоставимой с точностью ранее упомянутых моделей на основе искусственной нейронной сети. Даная модель показала среднюю абсолютную ошибку от 1,69% до 5,66% и R^2 от 0,92 до 0,97. Аль–Азани и др. [100] применили искусственную нейронную сеть с обучением по методу обратного распространения ошибки для прогнозирования реологических свойств бурового раствора на нефтяной основе. В этом исследовании для обучения ANN с обратным распространением ошибки было использовано небольшое количество записей полевых данных, 383: условная вязкость, плотность и содержание твердой фазы. Модель достигла умеренной точности прогнозирования со средней абсолютной ошибкой от 5,65% до 10,42% и R^2 от 0,77 до 0,91. В дальнейшем [101] нейронная сеть была обучена на 3000 полевых записей (условная вязкость, плотность, содержание твердой фазы) для прогнозирования реологических свойств бурового раствора на основе хлористого калия. Была достигнута точность прогнозирования со средней абсолютной ошибкой от 2,7% до 4,7% и R^2 от 0,89 до 0,97. Однако предложенная модель могла быть использована только для прогнозирования реологических свойств буровых растворов на основе хлористого калия. Эль–Кататни [102] разработал модель с искусственной нейронной сетью для прогнозирования реологических свойств бурового раствора на основе хлористого натрия и обучил ее на 816 записях данных. Полученный результат показал точность

прогнозирования реологических свойств (ПВ, n и средняя вязкость (КВ*)) с умеренно низкой погрешностью: средняя абсолютная ошибка от 3,98% до 7,7% и R^2 от 92 до 97 [102]. Основным ограничением данной модели является применимость только для прогнозирования реологических свойств буровых растворов на основе хлористого натрия. Говида и др. предложили модели на основе ANN для прогнозирования реологических свойств (ДНС, ПВ, n и К) хлоркальциевых буровых растворов.

Предложенные модели показали относительно высокую точность прогнозирования (средняя абсолютная ошибка от 3,2% до 10,42% и R^2 от 0,97 до 0,99). Возможности применения данных прогностических моделей также ограничены в силу того, что модели могут применяться только для буровых растворов на основе хлористого натрия. Говида и др. [103] также смоделировали реологические свойства бентонитосодержащего бурового раствора, применив алгоритм искусственной нейронной сети, основанный на наборе данных из 200 записей. Модель использовала плотность и условную вязкость в качестве входных данных для прогнозирования ДНС, ПВ и КВ бентонитовых буровых растворов и показала высокую прогностическую точность со средней абсолютной ошибкой от 2,8% до 6% и $R^2 > 0,90$. Тем не менее, все модели Говида построены для конкретных типов буровых растворов, что обычно ограничивает возможности их применения отдельными интервалами ствола скважины [103]. Гомаа и др. [104] разработали модель на основе искусственной нейронной сети с обучением по методу обратного распространения ошибки для прогнозирования реологических свойств буровых растворов высокой плотности на водной основе. Их модель была обучена на 1200 записях данных, в качестве входных переменных использовались только плотность и условная вязкость. Прогностическая точность модели составила: средняя абсолютная ошибка от 3,5% до 7,7% и R^2 от 0,94 до 0,97 [104]. Основным недостатком данной модели является ограниченность ее прогностических свойств конкретным типом бурового раствора, а именно, буровым раствором высокой плотности, применяемым при бурении на большие глубины.

Таким образом, вышеперечисленные модели прогнозирования реологических свойств буровых растворов характеризуются двумя основными ограничениями: (1) отсутствием обобщаемости, поскольку модели были специальным образом сконфигурированы для прогнозирования реологических свойств конкретных типов буровых растворов; и (2) необходимостью дальнейших расчетов для оценки определенных реологических свойств (т.е., выходными данными моделей являются показания вискозиметра, а не фактические реологические параметры).

В дополнение к вышеперечисленным исследованиям, Рази и др. [105] выполнили прогнозирование реологических свойств бурового раствора с помощью искусственной нейронной сети с использованием в качестве входных переменных экспериментальных данных, включая концентрации присадок к буровому раствору, например, полимеров и бентонита [105]. Для мониторинга реологических свойств биополимерного бентонитового бурового раствора Томива и др. [106] использовали искусственную нейронную сеть, позволяющую строить прогностические модели на основе лабораторных экспериментальных данных о концентрациях присадок к буровым растворам (бентонита и биополимера). Разработанные модели показали достаточно высокую точность прогнозирования: минимальное значение абсолютной процентной погрешности составило 1,387%, а $R^2 = 0,99$. Однако применимость данных моделей для надежного прогнозирования свойств буровых растворов в широком диапазоне полевых условий ограничена в силу того, что модели обучались и испытывались на реальных данных с конкретного месторождения [106].

В отличие от исследований в области прогнозирования реологических свойств буровых растворов, вопросы прогнозирования водоотдачи буровых растворов изучены достаточно мало. Голсефатан и Шабази [107] предложили три модели МО (искусственную нейронную сеть, адаптивную сеть на основе системы нечёткого вывода и машину опорных векторов наименьших квадратов) для прогнозирования водоотдачи нанокремнеземсодержащих буровых растворов на водной основе. Модели были обучены на наборе данных из 484 записей,

зарегистрированных для буровых растворов, рекомендованных для бурения. Для прогнозирования объема фильтрации применялись четыре входные функции, и машина опорных векторов наименьших квадратов (LSSVM) достигла наилучшей точности прогнозирования со средней абсолютной ошибкой 4,69% и R^2 0,994. При высокой точности прогнозирования данные модели страдают от отсутствия обобщаемости—поскольку могут прогнозировать водоотдачу только для нанокремнеземсодержащих жидкостей [107]. Голсефатан и Шабазы [103] также провели несколько более обобщенное исследование с моделью на основе искусственной нейронной сети для прогнозирования водоотдачи различных типов буровых растворов, содержащих наноматериалы. Модель была обучена и протестирована на основе 1003 экспериментальных данных для прогнозирования водоотдачи на основе семи исходных переменных, включая тип и концентрацию наночастиц, концентрацию KCl, условия испытаний (температуру и давление), время и скорость вращения. Модель генерировала низкие ошибки при прогнозировании (среднеквадратичное отклонение 0,95 и R^2 0,99)[103].

Лекомцев и др. [108] смоделировали фильтрационные характеристики нанобуровых растворов с использованием машин опорных векторов наименьших квадратов, а также машин экстремального обучения. Для прогнозирования фильтрационных характеристик наножидкостей они использовали те же семь входных переменных. Их оптимизированная LSSVM, оптимизированная методом роя частиц, при прогнозировании генерировала самые низкие ошибки (среднеквадратичное отклонение 0,2459 и R^2 0,999) [108]. Тем не менее, применение наночастиц в буровых растворах по-прежнему ограничено лабораторными исследованиями и несколькими мелкомасштабными полевыми испытаниями. Следовательно, модели прогнозирования водоотдачи, разработанные для нанобуровых растворов, не могут применяться для прогнозирования фильтрационных характеристик в полевых условиях.

С целью преодоления этих ограничений Гюль и Оорт [109] предприняли исследование с целью оценки водоотдачи буровых растворов на нефтяной и водной основе. Они применили множественную линейную регрессию, многослойный

перцептрон, машину опорных векторов, метод экстремального градиентного бустинга и метод случайного леса для прогнозирования водоотдачи с использованием 1298 записей полевых данных для двух типов буровых растворов на водной основе: бентонитсодержащего бурового раствора и безглинистого полимерного бурового раствора, а также 105 записей для буровых растворов на нефтяной основе. Четыре параметра бурового раствора, а именно, ПВ, ДНС, $\rho_{бр}$ и температура (FT), использовались в качестве входных данных для прогнозирования водоотдачи буровых растворов на водной основе. Для прогнозирования же водоотдачи растворов на водной основе использовались следующие входные данные: плотность, содержание воды, содержание нефти и электрическая стабильность. Модель, основанная на методе случайного леса, показала наивысшую точность прогнозирования: средняя абсолютная ошибка от 7,2% до 22,56% и R^2 от 0,70 до 0,85 [109]. Данный уровень точности прогнозирования является достаточно низким, несмотря на использование четырех входных параметров. Кроме того, модели МО в качестве входных данных использовали реологические параметры (пластическую вязкость и динамическое напряжение сдвига), которые в полевых условиях измеряются не на почасовой основе, а один или два раза в день, аналогично вязкости. Учитывая данный недостаток, модели на основе МО не могут применяться для прогнозирования водоотдачи на почасовой основе в полевых условиях.

История применения МО при прогнозировании реологических свойств буровых растворов показывает, что почти все модели разрабатывались под конкретные типы растворов, что накладывает серьезные ограничения на их прогностические возможности в режиме реального времени при бурении всего ствола скважины. В большинстве случаев при построении прогностических моделей реологических свойств буровых растворов использовались искусственные нейронные сети. К сожалению, данный метод требует настройки нескольких гиперпараметров, включая структуру сети, алгоритм обучения и функции активации [110], а прогностическая эффективность искусственной нейронной сети в значительной степени обусловлена этими параметрами. Существующие модели

прогнозирования водоотдачи с использованием методов МО, как правило, разрабатываются на материалах экспериментальных нанорастворов, что лишает их потенциала к применению в полевых условиях. Другим моделям требуются входные параметры, которые в настоящее время измеряются недостаточно часто, что не позволяет использовать их для прогнозирования водоотдачи в режиме реального времени. Кроме того, в настоящее время не существует модели МО, способной прогнозировать водоотдачу бурового раствора на основе наиболее регулярно измеряемых параметров (плотность, содержание твердой фазы, условная вязкость).

Учитывая ограничения и недостатки, присущие построенным ранее моделям на основе алгоритмов МО, можно утверждать, что в нефтегазовой индустрии существует запрос на разработку моделей с повышенной обобщаемостью, способных более точно прогнозировать реологические параметры и водоотдачу различных буровых растворов. Кроме того, несмотря на большое количество предпринятых в последнее время исследований в области применения методов МО для прогнозирования параметров буровых растворов, ни одно из них не ставило своей целью прогнозирование как реологических, так и фильтрационных свойств в режиме реального времени на основе одной и той же комбинации исходных переменных, которые могут быть получены с помощью простых, быстрых и часто осуществляемых измерений, а именно: плотности, содержанию твердой фазы и условной вязкости. В настоящем исследовании используется новый подход, основанный на современных оптимизированных гибридных моделях МО, способных прогнозировать реологические параметры (пластическую вязкость, динамическое напряжение сдвига) и водоотдачу буровых растворов на водной основе по всему стволу скважины в режиме реального времени с использованием плотности, содержания твердой фазы и условной вязкости в качестве исходных данных.

ГЛАВА 2. Методология, применяемая в новой прогностической системе

Учитывая, что данные, использованные в данном исследовании, являются представительными для общей популяции, одномерное статистическое описание данных до выполнения любых операций по обработке и моделированию должно определять методы прогнозирования и модели МО, предлагаемые в рамках данного исследования и использующие этот набор данных. В настоящей главе сначала будет представлено одномерное статистическое описание данных, а затем изложен метод проведения исследования и используемые в нем алгоритмы.

2.1. Характеристика набора данных по буровых растворах

Три параметра бурового раствора, водоотдача (Φ), пластическая вязкость (ПВ) и динамическое напряжение сдвига (ДНС) прогнозируются на основе часто измеряемых переменных: Плотность бурового раствора ($\rho_{бр}$), условная вязкость (УВ) и содержания твердой фазы (ТФ). Набор данных с измеренными значениями этих шести переменных был составлен по материалам 14 скважин (1160 записей данных), пробуренных с помощью буровых растворов на водной основе на двух нефтегазовых месторождениях на юго–западе Ирана.

Статистическая характеристика собранного набора данных приведена в таблице 2.1.

Таблица 2.1 – Статистическая характеристика набора данных из 1160 записей по 14 скважинам, пробуренным с применением буровых растворов на водной основе.

Переменные	$\rho_{бр}$	УВ	ТФ	Φ	ПВ	ДНС
Единицы измерения:	кг/м ³	с	%	см ³	мПа·с	Па
Среднее значение	1353,27	43,82	17,64	6,69	17,90	7,47
Стандартное отклонение	237,62	4,52	6,98	2,99	4,67	0,91
Дисперсия	56466,66	20,49	48,73	8,99	21,8	0,82
Минимум	1121,29	34,07	2,700	3,10	12,2	5,12
Максимум	2370,73	73,82	47,00	29,10	34,0	10,72
Асимметрия	2,54	1,91	2,09	3,02	1,82	1,09
Экцесс	5,76	5,99	4,71	13,53	2,42	2,00

Плотность бурового раствора в записях данных варьируется от 1121 до 2371 ($\text{кг}/\text{м}^3$), условная вязкость от 34 до 74 (с), содержание твердой фазы от 2,70 до 47,0 (%), водоотдача от 3,1 до 29,1 см^3 , пластическая вязкость от 12,2 до 34 ($\text{мПа}\cdot\text{с}$) и динамическое напряжение сдвига от 5.1 до 10.7 (Па). Кумулятивные функции распределения (CDF) вычисляются для набора данных из 1160 записей с использованием следующего уравнения для отображения форм распределения значений трех зависимых переменных (Φ , ПВ и ДНС) и трех независимых переменных ($\rho_{\text{бр}}$, УВ и ТФ).

$$\delta_w(x) = P(X \leq x), \text{ для всех } x \in R, \quad (2.1)$$

где; $\delta_x(x)$ = кумулятивная функция распределения; x = значения переменных данных; X = конкретное значение переменной x ; и R = набор значений. Распределения шести переменных, представленные на рисунке 2.1, характеризуются следующим образом:

$\rho_{\text{бр}} < 1250 \text{ кг}/\text{м}^3$ для ~35% записей данных, $1250 \leq \rho_{\text{бр}} \leq 1600 \text{ кг}/\text{м}^3$ для ~50% записей данных, и $\rho_{\text{бр}} > 1600 \text{ кг}/\text{м}^3$ для оставшихся 15% записей данных.

УВ < 43,5 с для ~26% записей данных, $43,5 \leq \text{УВ} \leq 55$ с для ~69% записей данных, и УВ > 55 с для ~5% записей данных.

ТФ < 7.5 для ~30% записей данных, $7,5 \leq \text{ТФ} \leq 12,5$ для ~61% записей данных, и ТФ > 12,5 для ~9% записей данных.

$\Phi < 6 \text{ см}^3$ для ~30% записей данных, $6 \leq \Phi \leq 12 \text{ см}^3$ для ~62% записей данных, и $\Phi > 12 \text{ см}^3$ для ~8% записей данных.

ПВ < 16 $\text{мПа}\cdot\text{с}$ для ~27% записей данных, $14 \leq \text{ПВ} \leq 24 \text{ мПа}\cdot\text{с}$ для ~60% записей данных, и ПВ > 23 $\text{мПа}\cdot\text{с}$ для ~13% записей данных.

ДНС < 14 Па для ~31% записей данных, $14 \leq \text{ДНС} \leq 18$ Па для ~62% записей данных, и ДНС > 18 Па для ~7% записей данных.

СВФ (рисунок 2.1) также показывают, что переменные ДНС и УВ почти нормально распределены, тогда как переменные $\rho_{\text{бр}}$, ТФ, Φ и ПВ не соответствуют нормальному распределению.

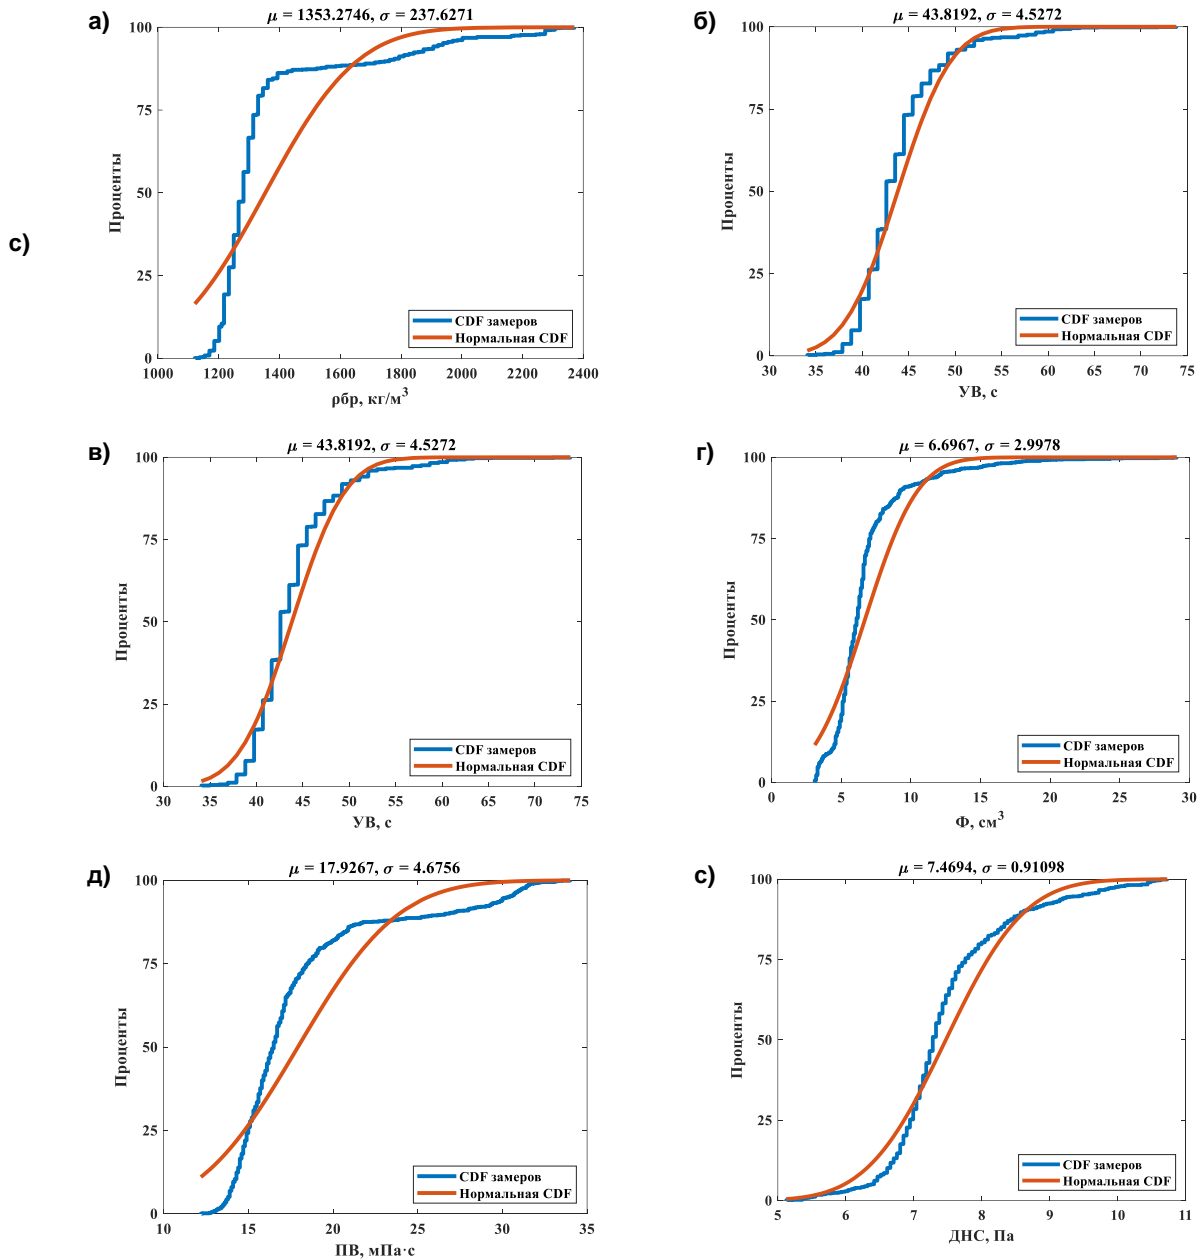


Рисунок 2.1 – CDF для каждого из шести параметров бурового раствора, оцениваемых с помощью моделей гибридного МО. Переменными являются: а) $\rho_{бр}$; б) УВ; в) ТФ г) Φ ; д) ПВ; и е) ДНС. Синие линии отображают измеренные распределения данных, тогда как красные линии отображают нормальные распределения на основе средних и стандартных отклонений зарегистрированных распределений.

Данные, записанные на месторождении в лаборатории буровых жидкостей, обычно содержат некоторые внутренние ошибки, связанные с неправильной калибровкой оборудования, используемого при проведении испытаний, и/или

человеческими ошибками при проведении и записи этих испытаний. Следовательно, перед тем как приступить к моделированию машинного обучения, собранный набор данных о буровых жидкостях требует предварительной обработки для обнаружения выбросов и исключения неточных записей. Для этой цели была применена фильтрация данных с использованием Махаланобисовского расстояния (MD) в сочетании с результатами прогноза алгоритма гауссового процесса регрессии (ГП). Этот метод позволил выявить 42, 44 и 50 записей данных как выбросы в показателях фильтрации, пластической вязкости и динамического касательного напряжения, соответственно. Затем предварительно обработанный набор данных был случайным образом разделен на два подмножества записей: 80% для обучения и 20% для тестирования.

2.2. Теоретическое описание предиктивных алгоритмов

В настоящем исследовании в качестве предиктивных алгоритмов используются LSSVM и метод многослойного экстремального машинного обучения (MELM). Данные алгоритмы были выбраны на основе их высокой предиктивной производительности при решении задач на основе регрессии в сочетании с алгоритмами оптимизации [75–87]. В следующих главах кратко приведены теоретические основы работы этих двух предикторов.

2.2.1. Метод наименьших квадратов опорных векторов (LSSVM)

LSSVM представляет собой модифицированную версию метода опорных векторов (SVM) и широко используется для решения прогностических задач регрессии и классификации. Поскольку равенства заменяют неравенства, используемые в алгоритме SVM, контролируемый метод LSSVM может решать задачи квадратичного программирования с более высокой вычислительной производительностью, чем SVM. Уравнение регрессии, используемое в модели LSSVM, выражается следующим уравнением:

$$y(x, w) = \sum_{i=1}^n w_i \theta_i(x) + b, \quad (2.2)$$

Где $\theta_i(x)$ и y обозначают, соответственно, функцию, используемую для картирования зависимых переменных в многомерном пространстве и их привязки к выходным переменным, w обозначает весовой вектор, b обозначает значение смещения.

Цель функции и условия ограничения для регрессии LSSVM определяются следующими уравнениями [119]:

$$\min \frac{1}{2} w^2 + \frac{1}{2} \gamma \sum_{i=1}^N \varepsilon_i^2, \quad (2.3)$$

$$\text{subjected to } \begin{cases} \gamma_i = w^T \cdot \theta(x) + \varepsilon_i + b, \\ \varepsilon_i \geq 0 \end{cases}, \quad (2.4)$$

где γ – параметр регуляризации, который необходимо оптимизировать. Компромисс между минимизацией ошибок обучения и плавностью устанавливается этим параметром регуляризации (γ), N и ε_i обозначают, соответственно, количество записей данных и связанную с записью погрешность i .

Для оптимизации обычно используется алгоритм Лагранжа:

$$L(w, b, \varepsilon, a) = \gamma \sum_{i=1}^N \varepsilon_i^2 + \frac{1}{2} w + \sum_{i=1}^N a_i \{ w^T \cdot \theta(x_i) + b + \varepsilon_i - \gamma_i \}, \quad (2.5)$$

где a обозначает множители Лагранжа, которые могут быть как отрицательными, так и положительными. Применяя ограничения равенства теоремы Каруша–Куна–Такера, мы можем получить множители из уравнений 2.6 – 2.10:

$$\frac{\delta L}{\delta W} = 0 \rightarrow W = \sum_{i=1}^N \theta(x_i) a_i, \quad (2.6)$$

$$\frac{\delta L}{\delta b} = 0 \rightarrow b = \sum_{i=1}^N a_i = 0, \quad (2.7)$$

$$\frac{\delta L}{\delta \varepsilon_i} = 0 \rightarrow a_i = \gamma \varepsilon_i, \quad i = 1, 2, 3, \dots, N, \quad (2.8)$$

$$\frac{\delta L}{\delta a_i} = 0 \rightarrow a_i \{ w^T \cdot \theta(x_i) + b + \varepsilon_i - \gamma \varepsilon_i \} = \gamma \varepsilon_i, \quad i = 1, 2, 3, \dots, N. \quad (2.9)$$

И в результате:

$$w = \sum_{i=1}^N \theta(x_i) a_i = \sum_{i=1}^N \varepsilon_i \gamma \theta(x_i). \quad (2.10)$$

Уравнение 2.10 отображает веса (w), относящиеся к линейным комбинациям множителей Лагранжа для записей обучающих данных (x_i). Задача регрессии LSSVM может быть преобразована и упрощена до уравнения 2.11 [120,121], путем вычитания уравнения 2.10 из уравнения 2.3:

$$\gamma_i = \sum_{i=1}^N a_i K(x, x_i) + b, \quad (2.11)$$

где $K(x, x_i)$ и a_i представляют собой функцию ядра и множители Лагранжа соответственно.

Метод наименьших квадратов опорных векторов (LSSVM) предоставляет ряд преимуществ при моделировании: он математически разрешим, высокоточен и способен, при необходимости, иметь дело с ограниченными наборами данных. Недостаток метода LSSVM заключается в том, что его обучение и обобщение существенно зависят от типа используемой функции ядра и применяемых к ней значений гиперпараметров [122–125]. Таким образом, для надежного моделирования методом LSSVM необходимо выбрать соответствующую функцию ядра. Кроме того, важно применять алгоритмы оптимизации для поиска наиболее подходящих гиперпараметров для выбранной функции ядра [126]. Методы, применяемые для выбора функции ядра и оптимизации требуемых гиперпараметров, подробно описаны в разделе 2.5.2.

2.2.2. Метод многослойного экстремального машинного обучения (MELM)

Метод экстремального машинного обучения (ELM) был представлен Хуангом [127], который стремился создать быструю нейронную сеть прямого распространения. ELM превосходит ряд других ANN в части устойчивости, обобщаемости и скорости обучения. Параметры, применяемые к скрытому слою ELM, генерируются случайным образом.

Веса между скрытым и выходным слоями ELM аналитически рассчитываются обобщенной обратной связью Мура–Пенроуза. Регрессия ошибок

наименьших квадратов может быть использована для определения значений выходных весов ELM с помощью линейного преобразования. В отличие от часто используемого алгоритма многослойного перцептрона (MLP), в ELM отсутствуют итеративные требования к обратному распространению, затратные с точки зрения вычислений [128]. Базовая конфигурация ELM состоит из трех слоев: входного, скрытого и выходного (рисунок 2.2).




Рисунок 2.2 – Принципиальная диаграмма, представляющая однослойную модель ELM, где x_n и y_m обозначают входные и выходные переменные, w_{ij} – веса, применяемые к каждому узлу скрытого слоя (g_1 to g_2), и β_{jk} представляет смещение, используемое для скрытого слоя.

Для решения нелинейных и сложных задач сеть ELM часто требует большого количества нейронов в скрытом слое для достижения оптимальной точности прогнозирования во время обучения. Однако данный алгоритм не отличается высокой точностью и обобщающей способностью. В этой связи были разработаны альтернативные версии ELM с несколькими скрытыми слоями. Пан и др. [129] установили, что дополнительные скрытые слои могут значительно повысить производительность и точность ELM за счет уменьшения количества неприменимых и избыточных нейронов в скрытых слоях. MELM является усовершенствованной версией алгоритма ELM с несколькими скрытыми слоями. Данная модификация позволяет MELM отображать отношения, необходимые для

прогнозирования целевых переменных с большей точностью, чем стандартный алгоритм ELM. Отображение отношений переменных проводится путем определения значений, необходимых для весовой матрицы и вектора смещения, связанного со скрытыми слоями сети [130]. Ём и Квак [128] продемонстрировали превосходство MELM по сравнению с ELM при обработке больших, нелинейных и сложных наборов данных. Настройка MELM требует семь шагов [129]:

Шаг 1. Настраивается набор данных входных переменных X_0 и выходных переменных Y с m записями данных $[X_0, Y] = [x_i, y_i]$ ($i = 1, 2, \dots, m$) в матрицы X_0 и Y .

Шаг 2. Определяется количество скрытых слоев k и узлов для MELM, где каждый скрытый слой в сети включает в себя n узлов с функцией активации.

Шаг 3. Для каждого слоя за пределами входного слоя определяются случайно инициализированные веса W для узлов, соединяющих j -й и $(j-1)$ -й скрытые слои. Затем каждому из слоев присваиваются случайные смещения B , что приводит к уравнению:

$$W_{j-1,j} = [B_i W_{j-1,j}], \quad X_j = [1 X_{j-1}]^T, \quad (2.12)$$

где 1 обозначает единичный вектор–столбец размера m .

Шаг 4. Матрица H (вывод скрытого слоя) определяется с помощью уравнения:

$$H = g(W_{j-1,j} X_j). \quad (2.13)$$

Шаг 5. Если j меньше k , то инкрементируйте j , установите вход нового слоя в соответствие с выходом предыдущего слоя и переходите к третьему шагу.

$$X_{j-1} = H^T. \quad (2.14)$$

Шаг 6. Обеспечивая линейное решение наименьших квадратов, обратный вес Мура–Пенроуза $\text{pinv}()$ применяется для определения весов между выходным слоем и конечным скрытым слоем, в соответствии с следившем уравнением:

$$\beta = \text{pinv}(H^T) \times Y. \quad (2.15)$$

Шаг 7. Путем применения следующего уравнения прогнозируются выходные переменные:

$$\hat{Y} = (H^T \times \beta)^T. \quad (2.16)$$

Несмотря на описанные выше преимущества, методу MELM присущи два крупных недостатка, требующие пристального внимания: i) точность прогнозирования и обобщаемая способность MELM в значительной степени зависят от его архитектуры (т.е., соответствующего количества скрытых слоев и достаточного количества нейронов в каждом скрытом слое), ii) как и в случае с алгоритмом ELM, стандартной реализации MELM свойственно присвоение случайных весов и смещений узлам и скрытым слоям. Чтобы преодолеть эти ограничения и добиться от модели MELM максимальной эффективности, настоятельно рекомендуется выбрать оптимальное количество скрытых слоев и необходимое количества нейронов в каждом скрытом слое, а также использовать оптимизированные значения в качестве весов и смещений к этим слоям / узлам [131]. В настоящем исследовании применяются два строгих подхода к оптимизации для настройки оптимальной структуры сети MELM и оценки оптимизированных значений смещений и весов для использования в сети MELM. Процедура оптимизации, применяемая к модели MELM с вышеуказанной целью, подробно описана в разделе 2.5.1.

2.3. Алгоритмы оптимизации

2.3.1. Оптимизационный алгоритм Cuckoo (COA)

Раджабиун [132] разработал оптимизационный алгоритм Cuckoo как алгоритм эволюционной оптимизации, имитирующий поведение кукушки. Самка кукушки откладывает яйца в гнезда других видов. Яйца, отложенные таким образом и наиболее похожие на яйца птиц-хозяев, выживают, и хозяева непреднамеренно выращивают взрослую кукушку. С другой стороны, менее похожие яйца распознаются и выбрасываются птицами-хозяевами. Пригодность гнезд, существующих в некоторой области, измеряется количеством гнездящихся

в данной области кукушек. Кукушки постоянно ищут область с гнездами, где они могут добиться максимальной выживаемости яиц. Область с максимальным коэффициентом выживаемости яиц считается наиболее желанным (благоприятным) районом для кукушек. Следовательно, СОА оптимизирует такой параметр, как условие максимальной выживаемости яиц [132]. СОА успешно применяется для решения широкого спектра задач инженерной оптимизации, включая статистическое управление технологическими процессами [133], определение гарантийного срока [134], анализ процессов электрохимической обработки [135], прогнозирование спроса на энергию [136], планирование задач [137], анализ быстрозаряжающихся полимерных литий-ионных батарей [138], прогнозирование глобальных выбросов CO_2 [139].

Для решения задачи оптимизации необходимо сформировать массив значений влияющих переменных. Такой массив называется «средой обитания». Подобно другим эволюционным алгоритмам, СОА инициирует популяцию взрослых кукушек, которые откладывают яйца в гнездах присутствующих птиц-хозяев. Это осуществляется с помощью следующего уравнения:

$$\text{Habitat} = [p_1, p_2, p_3, \dots, p_{N_{\text{COA}}}], \quad (2.17)$$

где $p_1, p_2, p_3, \dots, p_{N_{\text{COA}}}$ – моделируемые переменные. Таким образом, оптимизация *Cuckoo* начинается с разработки матрицы среды обитания с размерностью $N_{\text{POP}} \times N_{\text{COA}}$.

Несмотря на то, что кукушки тщательно пытаются имитировать форму и цвет яиц птицы-хозяина, некоторые из яиц кукушек будут опознаны и уничтожены. Кукушки откладывают яйца в гнезда птиц-хозяев в радиусе яйцекладки (ELR). Радиус, в пределах которого откладываются яйца, определяется следующим уравнением:

$$ELR = a \frac{\text{Number of current cuckoos' eggs}}{\text{Total number of eggs}} \times (var_{hi} - var_{low}), \quad (2.18)$$

в котором var_{low} и var_{hi} обозначают, соответственно, нижний и верхний пределы значений переменных, а a является положительным целым числом,

определяющими ELR. Яйца кукушек в конечном итоге вылупляются, и их птенцы выращиваются птицами–хозяевами.

Целью каждой кукушки является максимизация положительного эффекта от среды обитания. Положительный эффект, связанный с каждой средой обитания относительно каждой локации, занимаемой кукушкой, рассчитывается по функции прибыли, определяемой следующим уравнением:

$$Pr\ ofit = F_p(p_1, p_2, p_3, \dots, p_N), \quad (2.19)$$

В реальных задачах обычно рассматривается минимизация целевой функции. В настоящем исследовании целевой функцией COA является среднеквадратичное отклонение (RMSE). Для минимизации RMSE необходимо рассматривать функцию прибыли отрицательной, как показано в приведенном ниже уравнении:

$$Cost = -Pr\ ofit = -F_p(Habitat) = -F_p(p_1, p_2, p_3, \dots, p_{N_{COA}}). \quad (2.20)$$

В настоящем исследовании COA должен внести предлагаемые решения (каждое решение будет содержать гиперпараметры для LSSVM или веса и смещения для MELM) в прогностические алгоритмы, чтобы оценить величины ошибок RMSE. Это осуществляется в каждой последовательности итераций, каждая из которых рассматривает свой набор прогрессивно улучшающихся решений. Алгоритм итеративно работает до тех пор, пока не будет достигнуто минимальное значение среднеквадратичного отклонение. Вышеописанный процесс оптимизации подробно изложен в разделе 2.5. На рисунке 3 представлена схема, описывающая реализацию COA [132].

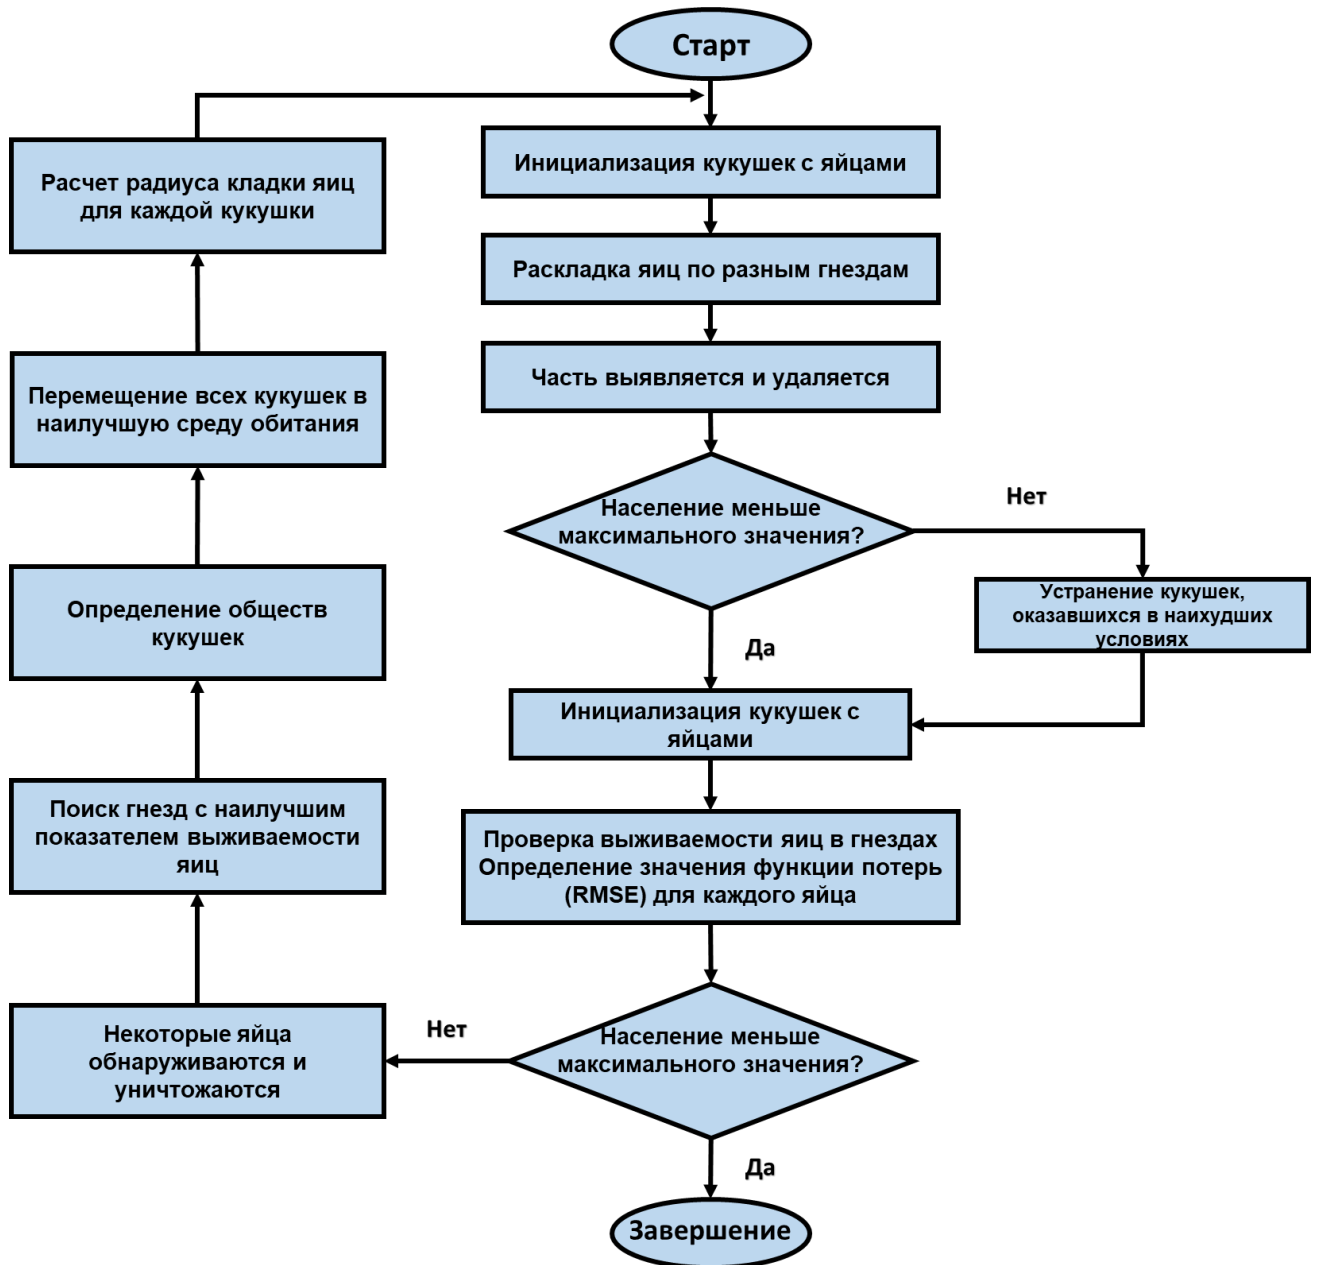


Рисунок 2.3 – Схема реализации алгоритма оптимизации Cuckoo.

2.3.2. Генетический алгоритм

В 1975 г. Холланд [140] разработала генетический алгоритм на основе эволюционных концепций генетики и естественного отбора. Этот стохастический подход может применяться для достижения относительно быстрого определения глобального оптимального решения для множественных задач оптимизации [141]. На рисунке 2.4 представлена схема, описывающая процесс реализации ГА.

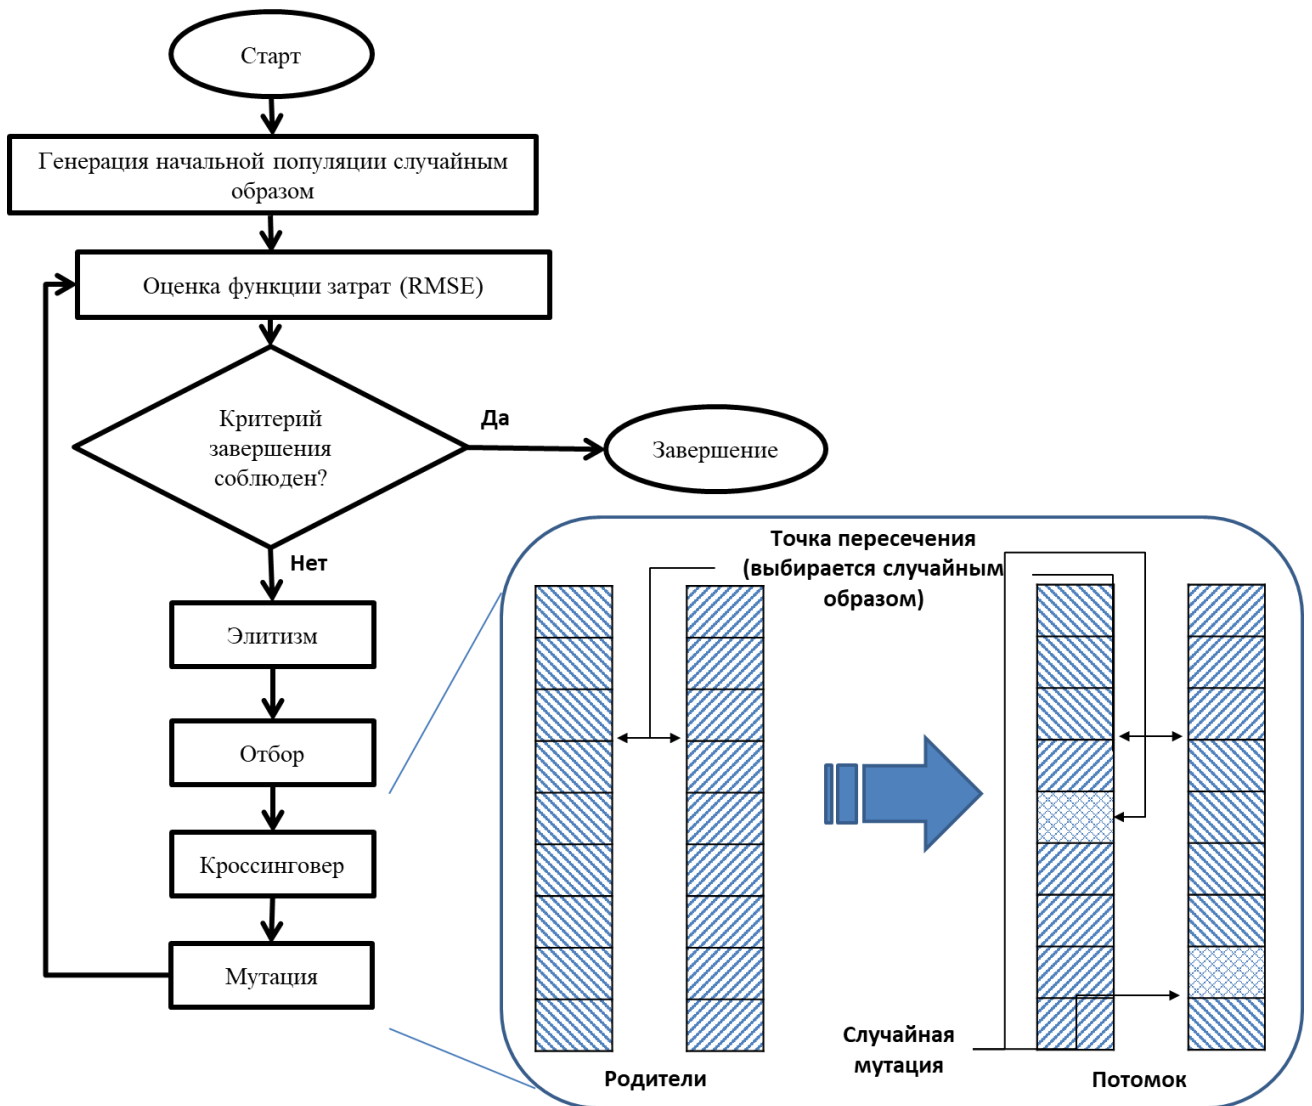


Рисунок 2.4 – Схема реализации генетического алгоритма (GA).

Модель GA случайным образом генерирует популяцию индивидов (хромосом). Эти случайные хромосомы оцениваются с помощью функции затрат. Далее происходит процесс размножения путем скрещивания и случайного отбора на основе значения функции затрат (RMSE), оцененной для каждой хромосомы. Хромосомам с более низкими значениями функции затрат обеспечиваются наилучшие шансы на размножение. Помимо скрещивания, имеют место мутации, сочетающие в себе особенности наиболее перспективных решений. Мутации помогают предотвратить попадание GA в ловушку возможного локального оптимума. Для обеспечения того, чтобы популяция наилучшего последующего поколения была такой же качественной, как и популяция текущего поколения, применяется метод элитизма, устранивающий наименее успешные индивиды. Такие

параметры ГА, как исследование пространства поиска и использование найденных успешных решений, совершенствуются путем скрещивания и мутаций соответственно. Последующие поколения популяции повторяют одну и ту же репродуктивную процедуру в серии итераций до тех пор, пока не будут достигнуты определенные критерии остановки [142].

ГА прост в реализации и достаточно гибок, чтобы эффективно работать с широким спектром задач по оптимизации [140]. В настоящем исследовании генетические алгоритмы должны внедрить сгенерированные решения (каждое из которых содержит потенциальные гиперпараметры для LSSVM или же веса и смещения для MELM) в прогностические алгоритмы, чтобы оценить их функцию затрат (*RMSE*) в каждой итерации на основе построенных прогнозов. Основываясь на вышеупомянутом процессе оптимизации, ГА продолжает итерации, приближаясь к минимальному значению затрат. Этот процесс оптимизации подробно описан в разделе 2.5.

2.4. Метрики погрешностей и оценки точности прогнозирования

Эффективность прогнозирования параметров буровых растворов посредством гибридных моделей МО оценивается по пяти метрикам погрешностей:

$$R^2 = 1 - \frac{\sum_{i=1}^n (TP_{measured_i} - TP_{predicted_i})^2}{\sum_{i=1}^n (TP_{predicted_i} - \frac{\sum_{i=1}^n TP_{measured_i}}{n})^2}, \quad (2.21)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (TP_{measured_i} - TP_{predicted_i})^2}, \quad (2.22)$$

$$SD = \sqrt{\frac{\sum_{i=1}^n (Er_i - Er_{mean})^2}{n-1}}, \quad (2.23)$$

$$APD = \frac{\sum_{i=1}^n PD_i}{n}, \quad (2.24)$$

$$AAPD = \frac{\sum_{i=1}^n |PD_i|}{n}, \quad (2.25)$$

$$PD_i = \frac{TP_{measured} - TP_{predicted}}{TP_{measured}} \times 100. \quad (2.26)$$

Коэффициент детерминации (R^2) и среднеквадратичного отклонение (RMSE) рассчитываются по уравнениям 2.21 и 2.22 соответственно. Уравнения 2.23 – 2.25 используются для расчета стандартного отклонения (SD), среднего значения относительного отклонения (APD) и среднего значения абсолютного относительного отклонения (AAPD). APD и AAPD требуют расчета процентного отклонения, выраженного уравнением 2.26.

Для оценки прогнозной эффективности моделей были выбраны пять различных мер погрешности. Как правило, выявление приоритетных метрик погрешности для сравнения прогностической эффективности моделей гибридного МО является неочевидной задачей. «Оценочный» анализ является простым, но эффективным методом, обеспечивающим объективное сравнение прогностической точности каждой модели. Данный метод просто ранжирует модели по эффективности прогнозирования, присваивая каждой модели оценку с учетом всех рассчитанных значений метрик ошибок. Анализируемым математическим моделям присваивается балльная оценка от 1 до «k» (т.е., общего количества оцениваемых моделей). Для каждой метрики погрешности оценка 1 присваивается модели с наихудшим качеством прогноза, а оценка k присваивается модели с наилучшим качеством [143,144]. Каждая модель оценивается по такой системе. Принимая во внимание все метрики погрешностей, включенные в анализ, итоговая оценка моделей определяется суммой оценок, полученных каждой моделью как для обучающих, так и для тестовых наборов данных. В нашем случае было разработано шесть автономных и гибридных моделей МО; следовательно, k равно шести, при

этом наиболее эффективная модель получает 6 баллов, а наименее эффективная – 1 балл.

Кроме того, для дальнейшей оценки эффективности прогнозирования разработанных моделей был также проведен метод визуальной оценки с помощью кривой ошибок регрессии (REC); оценка проводилась как для обучающих, так и для тестовых наборов данных. Кривая REC является регрессионным вариантом двумерной кривой операционных характеристик приёмника (ROC). Для кривой REC оси x и y представляют собой допуск погрешности и процент целевых прогнозов, полученных в пределах этого допуска погрешности, соответственно. Результирующая кривая оценивает кумулятивную функцию распределения погрешности между фактическим и прогнозируемым значениями. Функция погрешности, используемая кривой REC, может быть определена в виде либо квадратного остаточного, либо абсолютного отклонения. Для сравнения точности каждой модели измеряется площадь над кривой (AOC). Чем ниже значение AOC, тем выше точность модели. Таким образом, модель с самым низким значением AOC признается наиболее эффективной, а модель с самым высоким AOC признается наименее эффективной при прогнозировании целевых параметров [143,144].

2.5. Разработка гибридных моделей машинного обучения

В нефтегазовом секторе существует опыт успешного применения гибридных моделей МО для решения задач как регрессии, так и классификации. Области их применения включают в себя проектирование разработки месторождений, прогнозирование фильтрации флюидов в пласте [145], пористости и проницаемости [146], корреляции порового давления с глубиной [147], прогнозирования давления насыщения [148], скорости проходки [149], плотности бурового раствора [150], выявления литологических разностей [150] и фаций [151], прогнозирования распределения трещин по коллектору [152], повышения нефтеотдачи [153], определения устойчивости перекрывающей породы при проектировании подземных хранилищ CO₂ [154], геологическое моделирование

[155]. Опыт успешного применения гибридных моделей МО стимулирует разработку и апробацию новых алгоритмов для использования в качестве потенциальных прогностических моделей реологических и фильтрационных свойств буровых растворов.

Современный опыт применения гибридных форм метода наименьших квадратов опорных векторов и MELM с алгоритмами эволюционной оптимизации, такими как оптимизация методом роя частиц, GA, COA, затрагивает не только нефтегазовое дело, но и другие отрасли промышленности [46,76,115,122,156–159]. Вышеупомянутые исследования показали, что гибридные формы алгоритмов обеспечивают эффективность прогнозирования с высокой достоверностью значений целевых параметров. Таким образом, метод, предложенный в настоящем исследовании, гибридизировала GA и COA как два проверенных, надежных и эффективных алгоритма оптимизации с алгоритмами МО для разработки четырех высокопроизводительных моделей с целью точного прогнозирования реологических и фильтрационных свойств бурового раствора.

2.5.1 Прогностические модели на основе оптимизации MELM генетическим алгоритмом и алгоритмом оптимизации Cuckoo

Разработка модели MELM требует, чтобы веса и смещения изначально указывались случайным образом. Различные запуски такой модели приводят к варьированию точности прогнозирования. Определение оптимальной конфигурации MELM обеспечения надежности, точности и воспроизводимости результатов моделирования, является трудоемким итеративным процессом. Метод проб и ошибок для определения оптимальной конфигурации неэффективен. Процедуру настройки и конфигурирования модели можно существенно ускорить, гибридизируя MELM с алгоритмами оптимизации. На рисунке 2.5 представлена схема двухэтапного процесса оптимизации MELM генетическим алгоритмом и алгоритмом оптимизации Cuckoo. Первоначально оцениваются диапазоны для оценки количества скрытых слоев и узлов многослойной машины. Далее GA будет

использовать эти диапазоны в качестве пределов для оценки оптимальной структуры алгоритма MELM. Для каждой структуры, введенной с помощью GA, разрабатывается модель MELM и вычисляются значения среднеквадратичных отклонений для результатов прогнозирования. MELM оценивается десять раз для каждой рассматриваемой структуры, и структура с наименьшим средним значением RMSE для всех десяти запусков модели используется для оценки ее производительности.

После того, как установлена оптимальная структура MELM, проводится второй этап оптимизации для определения оптимальных весов и смещений. В качестве целевой функции алгоритмов оптимизации снова используется RMSE, а количество переменных решения в алгоритмах оптимизации устанавливается равным общему числу весов и смещений оптимальной структуры MELM. Каждому индивидуальному алгоритму оптимизации присваиваются начальные веса и значения смещений, которые оцениваются моделью MELM. Значения RMSE далее передаются обратно в алгоритмы оптимизации в виде затрат, пропорциональных значениям их заданных весов и смещений. Заданные значения весов и смещений модифицируются с учетом значений их функции затрат. Эти изменения приводят к тому, что RMSE постепенно сводится к минимуму для некоторых наиболее эффективных значений весов и смещений по последовательности итераций оптимизации. Итерации продолжаются до достижения конечного состояния. Далее строится модель MELM с оптимальными значениями весов и смещений из последней итерации; модель применяется к обучающим и тестовым наборам данных.

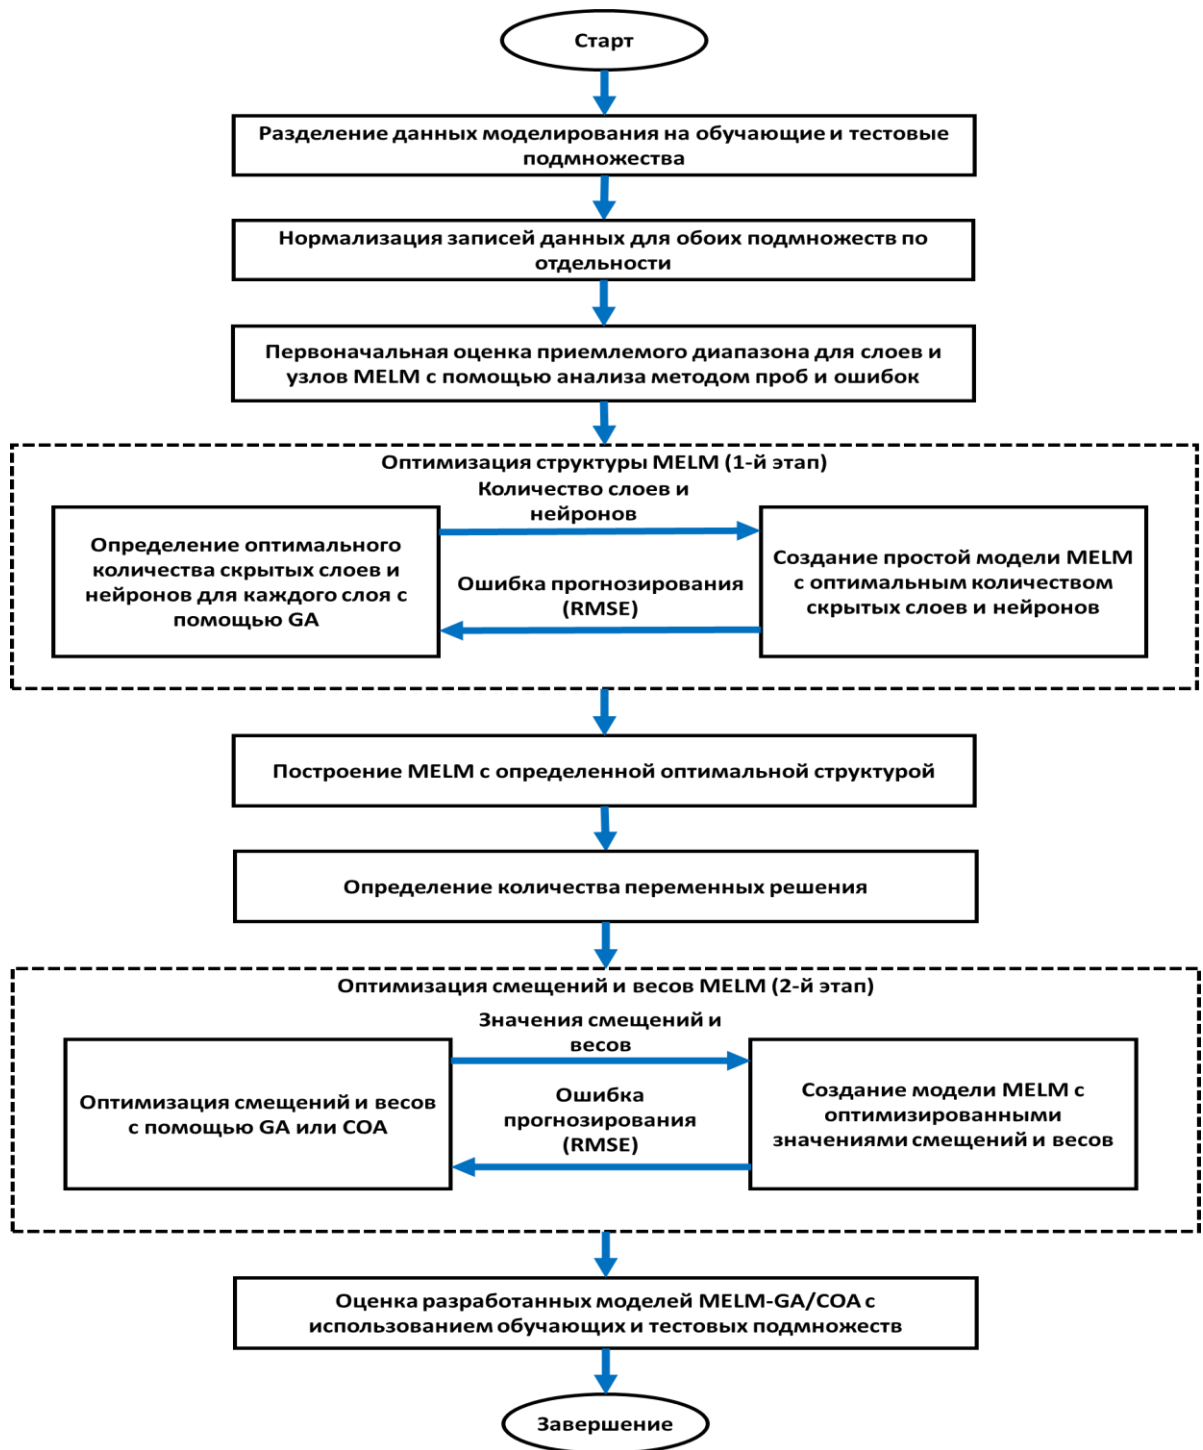


Рисунок 2.5 – Схема реализации гибридных моделей MELM–GA/COA (многослойная экстремальная обучающая машина, оптимизированная генетическим алгоритмом или и алгоритмом оптимизации Cuckoo), разработанных для прогнозирования реологических и фильтрационных свойств буровых растворов

Применяемая двухступенчатая стратегия оптимизации является менее затратной альтернативой традиционному методу случайного назначения при построении MELM. Она более эффективно идентифицирует количество скрытых слоев, а также нейронов и смещений в этих слоях. Применение такой стратегии оптимизации сокращает вычислительное время гибридных моделей (MELM-GA/COA) и существенно повышает их точность при прогнозировании целевых параметров бурового раствора.

Псевдокоды гибридных прогнозных моделей MELM/GA и MELM/COA представлены ниже:

Псевдокод для модели MELM-COA

Inputs

X_{train} : Training data with N_p features(rows) and N_{train} samples(columns)

Y_{train} : Training target vector of length N_{train}

X_{test} : Test data with N_p features(rows) and N_{test} samples(columns)

Y_{test} : Training target vector of length N_{test}

N_p : number of parameters to be optimized

N_c : initial number of cuckoos

$MAX_{CUCKOOS}$: maximum number of cuckoos at the same time

MIN_{EGGS} : minimum number of eggs for each cuckoo

MAX_{EGGS} : maximum number of eggs for each cuckoo

N_{iter} : maximum number of iterations in the algorithm

K : number of clusters in *kmeans* algorithm

λ : percent of flight distance for cuckoos

α : control parameter of egg laying

δ : population variance that cuts the optimization

LB: lower bound of the parameters

UB: upper bound of the parameters

N_{hidden} : number of hidden layers in the network

$N_{neurons}$: a vector of N_{hidden} elements where $N_{neurons}[i]$ indicates the number of neurons in i th layer of the network

outputs

Weights: weights of the best found network

▷ the symbol (▷) is used for comments

▷ $Cat(A, B)$ gets matrix $A_{w \times y}$ and matrix $B_{w \times z}$ and returns a matrix $C_{w \times q}$ where $q = y + z$

▷ $Zeros(A, B)$ returns a matrix with A rows and B columns with all entries set to zero

▷ $Random(S, [B, C])$ returns a uniformly random generated vector of values $\in [B, C]$ and length S

▷ $Sign(x) = \begin{cases} +1 & x \geq 0 \\ -1 & x < 0 \end{cases}$

▷ $\lfloor \cdot \rfloor$ is the floor function

▷ $argmin(A)$ returns the index of the smallest value in vector A

▷ $argsort(A)$ returns the index of values in vector A in ascending order

▷ $Kmeans(positions, K)$ return a list of length equal to number of points in positions matrix where

▷ i th entry entry specifies the cluster number of the corresponding point in i th column of positions

1 $globalBest \leftarrow$ empty vector

2 $globalBestCost \leftarrow +\infty$

▷ initialize egg laying center for each cuckoo

```

3  for  $i \leftarrow 1 \dots N_c$  do
4      cuckoo[i].center  $\leftarrow$  Random( $N_p$ , [LB, UB])
5  end for
6  for iteration  $\leftarrow 1 \dots N_{iter}$  do
7      sumEggs  $\leftarrow$  0
8       $\triangleright$  set the number of eggs for each cuckoo and accumulate total number of eggs
9      for  $i \leftarrow 1 \dots N_c$  do
10         cuckoo[i].numEggs  $\leftarrow$  [Random(1, [MIN_EGGS, MAX_EGGS])]
11         sumEggs  $\leftarrow$  sumEggs + cuckoo[i].numEggs
12     end for
13      $\triangleright$  Calculate Egg Laying Radius for each cuckoo
14     for  $i \leftarrow 1 \dots N_c$  do
15         cuckoo[i].ELR  $\leftarrow$  cuckoo[i].numEggs/sumEggs  $\times$   $\alpha \times$  (UB - LB)
16     end for
17      $\triangleright$  each cuckoo lays its eggs by dividing a (hyper)circle to equal segments
18      $\triangleright$  to search all over the current habitat
19     for  $i \leftarrow 1 \dots N_c$  do
20         params  $\leftarrow$  cuckoo[i].center
21         angle  $\leftarrow$  0
22         for  $j \leftarrow 1 \dots$  cuckoo[i].numEggs do
23              $r \leftarrow$  Random(1, [0 ... 1])  $\times$  cuckoo[i].ELR
24             for  $k \leftarrow 1 \dots N_p$  do
25                  $d \leftarrow$  sign(Random(1, [-1, 1]))
26                  $\triangleright$  eggs[k, j] is the kth parameter of the jth egg
27                 cuckoo[i].eggs[k, j]  $\leftarrow$  params[k] +  $d \times (r \times \cos(\text{angle}) + r \times \sin(\text{angle}))$ 
28                  $\triangleright$  boundry check
29                 cuckoo[i].eggs[k, j]  $\leftarrow$  min(max(cuckoo[i].eggs[j, k], LB), UB)
30             end for
31             angle  $\leftarrow$  angle +  $(2 \times \pi) / (\text{cuckoo}[i].\text{numEggs})$ 
32         end for
33     end for
34      $\triangleright$  put all of the centers and eggs in a single positions matrix to evaluate
35     positions  $\leftarrow$  empty matrix
36     cost  $\leftarrow$  Zeros( $N_c + \text{sumEggs}$ , 1)
37     for  $i \leftarrow 1 \dots N_c$  do
38         positions  $\leftarrow$  Cat(positions, cuckoo[i].center)
39         positions  $\leftarrow$  Cat(positions, cuckos[i].eggs)
40     end for
41     for  $i \leftarrow 1 \dots (N_c + \text{sumEggs})$  do
42          $W \leftarrow$  positions[:, i]  $\triangleright$  the ith column of the matrix
43         cost[i]  $\leftarrow$  train_and_evaluate_MELM( $X_{train}, Y_{train}, X_{test}, Y_{test}, N_{hidden}, N_{neurons}, W$ )
44     end for
45      $\triangleright$  update the best solution so far if necessary
46     minIndex  $\leftarrow$  argmin(cost)
47     if cost[minIndex] < globalBestCost then
48         globalBestCost  $\leftarrow$  cost[minIndex]
49         globalBest  $\leftarrow$  positions[:, minIndex]
50     end if
51      $\triangleright$  if total number of eggs and cuckoos exceeds the limit, delete the worst
52      $\triangleright$  performing ones
53     if  $N_c + \text{sumEggs} > \text{MAX}_{cuckoos}$  then
54         sortIndex  $\leftarrow$  argsort(cost)
55         cost  $\leftarrow$  cost[sortIndex]  $\triangleright$  sort cost values from smallest to the largest
56         positions  $\leftarrow$  positions[:, sortIndex]  $\triangleright$  sort positions according their cost
57          $N_c \leftarrow \text{MAX}_{cuckoos}$ 

```

```

49     |  $positions \leftarrow positions[:, 1 \dots N_c] \triangleright$  retain only the best  $N_c$  solutions
50 end if
     $\triangleright$  use kmean clustering method to group cuckoos into  $K$  distinctive groups
51  $clusterNumberIndex \leftarrow Kmeans(positions, \mathbf{K})$ 
     $\triangleright$  calculate the average cost for each cluster
52  $clusterMean \leftarrow Zeros(K, 1)$ 
53  $clusterMemberCounter \leftarrow Zeros(K, 1)$ 
54  $numberOfPositions \leftarrow Size(positions, 2)$ 
55 for  $i \leftarrow 1 \dots numberOfPositions$  do
56     |  $j \leftarrow clusterIndex[i]$ 
57     |  $clusterMean[j] \leftarrow clusterMean[j] + cost[j]$ 
58     |  $clusterMemberCounter[j] \leftarrow clusterMemberCounter[j] + 1$ 
59 end for
60 for  $i \leftarrow 1 \dots K$  do
61     |  $clusterCostAverage[i] \leftarrow clusterCostAverage[i]/clusterMemberCounter[i]$ 
62 end for
     $\triangleright$  find the best performing cuckoo (goal point) in the best cluster
63  $bestClusterIndex \leftarrow argmin(clusterCostAverage)$ 
64  $goalPositionCost \leftarrow +\infty$ 
65 for  $i \leftarrow 1 \dots numberOfPositions$  do
66     |  $j \leftarrow clusterIndex[i]$ 
67     | if  $(j = bestClusterIndex)$  and  $goalPositionCost > cost[j]$  then
68         |  $goalPositionCost \leftarrow cost[j]$ 
69         |  $goalPoint \leftarrow positions[:, i]$ 
70     | end if
71 end for
     $\triangleright$  move all of the cuckoos towards the goal point and calculate their cost
72  $cost \leftarrow Zeros(numberOfPositions, 1)$ 
73 for  $i \leftarrow 1 \dots numberOfPositions$  do
74     |  $\triangleright$  * is elementwise multiplication
75     |  $d \leftarrow (goalPoint - positions[:, i]) .* Random(N_p, [0,1])$ 
76     |  $positions[:, i] \leftarrow positions[:, i] + d$ 
77     |  $\triangleright$  elementwise min and max
78     |  $positions[:, i] \leftarrow \min(\max(positions[:, i], \mathbf{LB}), \mathbf{UB})$ 
79     |  $W \leftarrow positions[:, i] \quad \triangleright$  the  $i$ th column of the matrix
80     |  $cost[i] \leftarrow train\_and\_evaluate\_MELM(\mathbf{X}_{train}, \mathbf{Y}_{train}, \mathbf{X}_{test}, \mathbf{Y}_{test}, N_{hidden}, N_{neurons}, W)$ 
81 end for
     $\triangleright$  check and update (if necessary) the best cuckoo (solution) so far
82  $sortIndex \leftarrow argsort(cost)$ 
83  $cost \leftarrow cost[sortIndex]$ 
84  $positions \leftarrow positions[:, sortIndex]$ 
85 if  $cost[1] < globalBestCost$  then
86     |  $globalBestCost \leftarrow cost[1]$ 
87     |  $globalBest \leftarrow positions[:, 1]$ 
88 end if
     $\triangleright$  replace the worst performing cuckoo with the best cuckoo to let the best
     $\triangleright$  to live beyond generations
89  $positions[:, numberOfPositions] \leftarrow globalBest$ 
90  $\triangleright$  replace the second worst performing cuckoo with a variant of the best cuckoo
91  $positions[:, numberOfPositions - 1] \leftarrow Random(N_p, [0,1]) .* globalBest$ 
92 end for
93  $Weights \leftarrow globalBest$ 
94 return  $Weights$ 

```

tain_and_evaluate_MELM

Inputs

\mathbf{X}_{train} : Training data with N_p features(rows) and N_{train} samples(columns)
 \mathbf{Y}_{train} : Training target vector of length N_{train}
 \mathbf{X}_{test} : Test data with N_p features(rows) and N_{test} samples(columns)
 \mathbf{Y}_{test} : Training target vector of length N_{test}
 N_{hidden} : number of hidden layers in the network
 $N_{neurons}$: a vector of N_{hidden} elements where $N_{neurons}[i]$ indicates the number of neurons in i th layer of the network
 $\mathbf{Weights}$: a vector containing all of the weights in the network

Output

RMSE: Root Mean Squared Error for test data

▷ the symble (▷) is used for comments

▷ $List(N)$ return an empty list with elements that can be assigned any arbitrary object

▷ $Reshape(A, B, C)$ return a $B \times C$ matrix with elements copied from vector A

▷ Create layers and initialize their weights from **Weights**

```

1 layers ← List( $N_{hidden}$ )
2 numInputs ←  $N_p$ 
3 for  $i \leftarrow 1 \dots N_{hidden}$  do
4     numLayerW ← numInputs ×  $N_{neurons}[i]$ 
5      $w \leftarrow \mathbf{Weights}[1: numLayerW]$ 
6     layers[ $i$ ]. $w \leftarrow Reshape(w, numInputs, N_{neurons}[i])$ 
7      $\mathbf{Weights} \leftarrow \mathbf{Weights}[numLayerW + 1: end]$ 
8     numInputs ←  $N_{neurons}[i]$ 
9 end for
▷ apply each layer's weights to the inputs until final outputs are produced
10 inTrain ←  $\mathbf{X}_{train}$ 
11 inTest ←  $\mathbf{X}_{test}$ 
12 for  $i \leftarrow 1 \dots N_{hidden}$  do
13     outTrain ← inTrainT × layers[ $i$ ]. $w$  ▷ matrix multiplication
14     inTrain ← RBF(outTrain) ▷ inTrain[ $i, j$ ] = exp(-outTrain[ $i, j$ ]2)
15     outTest ← inTestT × layers[ $i$ ]. $w$ 
16     inTest ← RBF(outTest)
17 end for
▷ Compute the final transform matrix
18  $B \leftarrow (outTrain)^{-1} \times \mathbf{Y}_{train}$ 
19  $Y_{pred} \leftarrow (outTest^T \times B)^T$ 
▷ Compute Root Mean Squared Error
20  $rmse \leftarrow \sqrt{\frac{1}{N_{test}} \sum_i^{N_{test}} (\mathbf{Y}_{test}[i] - Y_{pred}[i])^2}$ 
21 return rmse

```

Псевдокод для модели MELM-GA

Inputs

\mathbf{X}_{train} : Training data with N_p features(rows) and N_{train} samples(columns)
 \mathbf{Y}_{train} : Training target vector of length N_{train}
 \mathbf{X}_{test} : Test data with N_p features(rows) and N_{test} samples(columns)
 \mathbf{Y}_{test} : Training target vector of length N_{test}
 N_p : number of parameters to be optimized
 N_c : initial number of chromosomes (solutions)
 N_{iter} : maximum number of iterations in the algorithm
 P_c : crossover (reproduction) percentage

P_m : mutation percentage
 γ : crossover coefficient parameter range
 μ : mutation rate
 β : selection pressure
LB: lower bound of the parameters
UB: upper bound of the parameters
 N_{hidden} : number of hidden layers in the network
 $N_{neurons}$: a vector of N_{hidden} elements where $N_{neurons}[i]$ indicates the number of neurons in i th layer of the network

outputs

γ : regularization parameter of the LSSVM method
 σ : Radial Basis Function (RBF) kernel width

▷ the symble (\triangleright) is used for comments
 ▷ $Cat(A, B)$ gets matrix $A_{w \times y}$ and matrix $B_{w \times z}$ and returns a matrix $C_{w \times q}$ where $q = y + z$
 ▷ $Zeros(A, B)$ returns a matrix with A rows and B columns with all entries set to zero
 ▷ $Random(p, q, [B, C])$ returns a uniformly random generated $p \times q$ matrix of values $\in [B, C]$
 ▷ $RandomN(p, q, [B, C])$ returns a $p \times q$ matrix of values $\in [B, C]$ sampled from normal distribution
 ▷ $\lfloor \cdot \rfloor$ is the floor function
 ▷ $argmin(A)$ returns the index of the smallest value in vector A
 ▷ $argsort(A)$ returns the index of values in vector A in ascending order

```

1  numX  $\leftarrow 2 \times \lfloor P_c \times N_c / 2 \rfloor$ 
3  numM  $\leftarrow \lfloor P_m \times N_c \rfloor$ 
   ▷ initialize the population with random values where each column of pop is a solution
3  pop  $\leftarrow Random(N_p, N_c, [LB, UB])$ 
   ▷ evaluate the chromosomes
4  cost  $\leftarrow Zeros(N_c, 1)$ 
5  for i  $\leftarrow 1 \dots N_c$  do
6     W  $\leftarrow pop[:, i]$ 
7     cost[i]  $\leftarrow train\_and\_evaluate\_MELM(X_{train}, Y_{train}, X_{test}, Y_{test}, N_{hidden}, N_{neurons}, W)$ 
8  end for
   ▷ find the best solution of initial populatio
9  bestIndex  $\leftarrow argmin(cost)$ 
10 globalBest  $\leftarrow pop[:, bestIndex]$ 
11 globalBestCost  $\leftarrow cost[bestIndex]$ 
   ▷ iterate for  $N_c$  iterations
11 for iteration  $\leftarrow 1 \dots N_{iter}$  do
   ▷ calculate selection chance for each chromosome based of their cost and make
   ▷ cumulative sum array
12  p = Zeros( $N_c$ , 1)
13  sumP  $\leftarrow 0$ 
14  for i  $\leftarrow 1 \dots N_c$  do
15     | p[i]  $\leftarrow sumP + e^{-\beta \times cost[i]}$ 
16     | sumP  $\leftarrow sumP + p[i]$ 
17  end for
   ▷ normalize chances to be probabilities
18  for i  $\leftarrow 1 \dots N_c$  do
19     | p[i]  $\leftarrow p[i] / sumP$ 
20  end for
   ▷ create crossover population
21  popX  $\leftarrow Zeros(N_p, numX)$ 
22  costX  $\leftarrow Zeros(1, numX)$ 
23  i  $\leftarrow 1$ 
24  while i < numX do
   ▷ select first parent for crossover

```

```

25    $r \leftarrow \text{Random}(1, 1, [0, 1])$ 
26    $\text{parent1Index} \leftarrow 1$ 
27   while  $r > p[\text{parent1Index}]$  do
28     |  $\text{parent1Index} \leftarrow \text{parent1Index} + 1$ 
29   end while
     $\triangleright$  select second parent for crossover
30    $r \leftarrow \text{Random}(1, 1, [0, 1])$ 
31    $\text{parent2Index} \leftarrow 1$ 
32   while  $r > p[\text{parent2Index}]$  do
33     |  $\text{parent2Index} \leftarrow \text{parent2Index} + 1$ 
34   end while
     $\triangleright$  crossover
35   for  $j \leftarrow 1 \dots N_p$  do
36     |  $\alpha \leftarrow \text{Random}(1, 1, [-\gamma, 1 + \gamma])$ 
37     |  $\text{popX}[j, i] \leftarrow \alpha \times \text{pop}[j, \text{parent1Index}] + (1 - \alpha) \times \text{pop}[j, \text{parent2Index}]$ 
38     |  $\text{popX}[j, i + 1] \leftarrow \alpha \times \text{pop}[j, \text{parent2Index}] + (1 - \alpha) \times \text{pop}[j, \text{parent1Index}]$ 
     $\triangleright$  check for boundry violations
39     |  $\text{popX}[j, i] \leftarrow \min(\max(\text{popX}[j, i], \mathbf{LB}), \mathbf{UB})$ 
40     |  $\text{popX}[j, i + 1] \leftarrow \min(\max(\text{popX}[j, i + 1], \mathbf{LB}), \mathbf{UB})$ 
41   end for
     $\triangleright$  evaluate the new offsprings
42    $W \leftarrow \text{popX}[:, i]$ 
43    $\text{costX}[i] \leftarrow \text{train\_and\_evaluate\_MELM}(X_{\text{train}}, Y_{\text{train}}, X_{\text{test}}, Y_{\text{test}}, N_{\text{hidden}}, N_{\text{neurons}}, W)$ 
44    $W \leftarrow \text{popX}[:, i + 1]$ 
45    $\text{costX}[i] \leftarrow \text{train\_and\_evaluate\_MELM}(X_{\text{train}}, Y_{\text{train}}, X_{\text{test}}, Y_{\text{test}}, N_{\text{hidden}}, N_{\text{neurons}}, W)$ 
46    $i \leftarrow i + 2$ 
47 end while
     $\triangleright$  create mutation population
48    $\text{popM} \leftarrow \text{Zeros}(N_p, \text{num}_M)$ 
49    $\text{costM} \leftarrow \text{Zeros}(1, \text{num}_M)$ 
50    $\text{mutationRange} \leftarrow 0.1 \times (\mathbf{UB} - \mathbf{LB})$ 
51 for  $i \leftarrow 1 \dots \text{numM}$  do
     $\triangleright$  select and mutate a chromosome
52    $\text{indexM} \leftarrow \lfloor \text{Random}(1, 1, [1, N_c]) \rfloor$ 
53   for  $j \leftarrow 1 \dots N_p$  do
54     |  $r \leftarrow \text{Random}(1, 1, [0, 1])$ 
55     | if  $r \leq \mu$  then
56       |  $\text{popM}[j, i] \leftarrow \text{pop}[j, \text{indexM}] + \text{mutationRange} \times \text{RandomN}(1, 1)$ 
57     | else
58       |  $\text{popM}[j, i] \leftarrow \text{pop}[j, \text{indexM}]$ 
59     | end if
     $\triangleright$  evaluate the new chromosome
60     |  $\text{popM}[j, i] \leftarrow \min(\max(\text{popM}[j, i], \mathbf{LB}), \mathbf{UB})$ 
61   end for
     $W \leftarrow \text{popM}[:, i]$ 
62    $\text{costM}[i] \leftarrow \text{train\_and\_evaluate\_MELM}(X_{\text{train}}, Y_{\text{train}}, X_{\text{test}}, Y_{\text{test}}, N_{\text{hidden}}, N_{\text{neurons}}, W)$ 
63 end for
     $\triangleright$  concatenate all populations and sort them based on their cost
64    $\text{pop} \leftarrow \text{Cat}(\text{pop}, \text{popX})$ 
65    $\text{pop} \leftarrow \text{Cat}(\text{pop}, \text{popM})$ 
66    $\text{cost} \leftarrow \text{Cat}(\text{cost}, \text{costX})$ 
67    $\text{cost} \leftarrow \text{Car}(\text{cost}, \text{costM})$ 
68    $\text{sortOrder} \leftarrow \text{argsort}(\text{cost})$ 
69    $\text{pop} \leftarrow \text{pop}[:, \text{sortOrder}]$ 
70    $\text{cost} \leftarrow \text{cost}[\text{sortOrder}]$ 
71

```

```

72   | ▷ retain only the  $N_c$  best chromosomes
73   |  $pop \leftarrow pop[:, 1 \dots N_c]$ 
74   |  $cost \leftarrow cost[:, 1 \dots N_c]$ 
75   | ▷ update the global best
76   | if  $globalBestCost > cost[1]$  then
77   |   |  $globalBest \leftarrow pop[:, 1]$ 
78   |   |  $globalBestCost \leftarrow cost[1]$ 
79   | end if
80 end for
81  $Weights \leftarrow globalBest$ 
82 return  $Weights$ 

```

2.5.2. Прогностические модели на основе оптимизации LSSVM генетическим алгоритмом и алгоритмом оптимизации Cuckoo

Производительность модели LSSVM в значительной степени определяется используемой функцией ядра и параметром регуляризации, поэтому выбор подходящей функции ядра имеет решающее значение для оптимизации модели. Эффективность функции ядра зависит от распределения и связей переменных набора данных, при этом стандартного способа определения оптимальной функции ядра не существует [149,160,161]. В этой связи в настоящем исследовании был проведен анализ методом проб и ошибок с использованием четырех часто используемых функций ядра (таблица 2.2).

Таблица 2.2 – Функции ядра, обычно используемые в моделях LSSVM.

Тип функции ядра	Уравнение	Описания параметров
Линейная функция (Lin)	$K(x, x_i) = x_i^T x$	–
Полиномиальная функция (Poly)	$K(x, x_i) = \left(t + \frac{x_i^T x}{x} \right)^d$	d и t обозначают, соответственно, степень и точку пересечения оси полиномиальной функции.
Радиальная базисная функция (RBF)	$K(x, x_i) = \exp\left(-\frac{\ x - x_i\ ^2}{\sigma^2}\right)$	σ^2 обозначает дисперсию ядра Гаусса.
Многослойный перцептрон (MLP)	$K(x, x_i) = \tanh(kx_i^T x + \theta)$	k и θ представляют собой параметры масштаба и смещения соответственно.

После выбора наиболее эффективной функции ядра LSSVM необходимо определить оптимальные значения гиперпараметров. С этой целью используются

алгоритмы оптимизации: GA и cuckoo optimization algorithm. Для решения системы линейных уравнений и получения приемлемых начальных значений гиперпараметров для моделей LSSVM использовался метод сопряженного градиента благодаря своей эффективности и вычислительную скорости.

При вводе наилучшие значения гиперпараметров, полученных методом сопряжённого градиента, в алгоритмы оптимизации в качестве текущего наилучшего решения, алгоритмы оптимизации легче сходятся к оптимальным решениям по сравнению с наполнением моделей случайными значениями гиперпараметров. Основываясь на текущем наилучшем решении, алгоритмы оптимизации улучшают свои первоначально присвоенные решения для каждого индивида на основе собственных механизмов. Эти значения вводятся в LSSVM как новые значения гиперпараметров. Используя каждый набор значений гиперпараметров, строятся модели LSSVM, а RMSE передается обратно в алгоритм оптимизации в виде значений затрат, связанных с каждым набором введенных значений гиперпараметров. RMSE рассчитывается путем сравнения прогнозируемых и целевых значений параметров. Далее выбирается наилучшее решение для каждой итерации оптимизатора путем сравнения затрат, достигнутых каждым индивидом в популяции. Наиболее эффективные индивиды сохраняются генетическим алгоритмом и становятся родителями следующего поколения индивидов. В алгоритме оптимизации Cuckoo глобальный наиболее эффективный индивидум в каждой итерации переносится на следующую итерацию. В течение последовательности итераций алгоритмы оптимизации выполняют действия, приводящие к минимизации RMSE. Эти повторения продолжаются до достижения конечного состояния. Путем выбора наилучших значений гиперпараметров, достигнутых в последней итерации, строится модель LSSVM и применяется к обучающим и тестовым наборам данных. На рисунке 2.6 представлена схема реализации машины опорных векторов наименьших квадратов, включающей одноэтапный процесс оптимизации с использованием GA или COA.

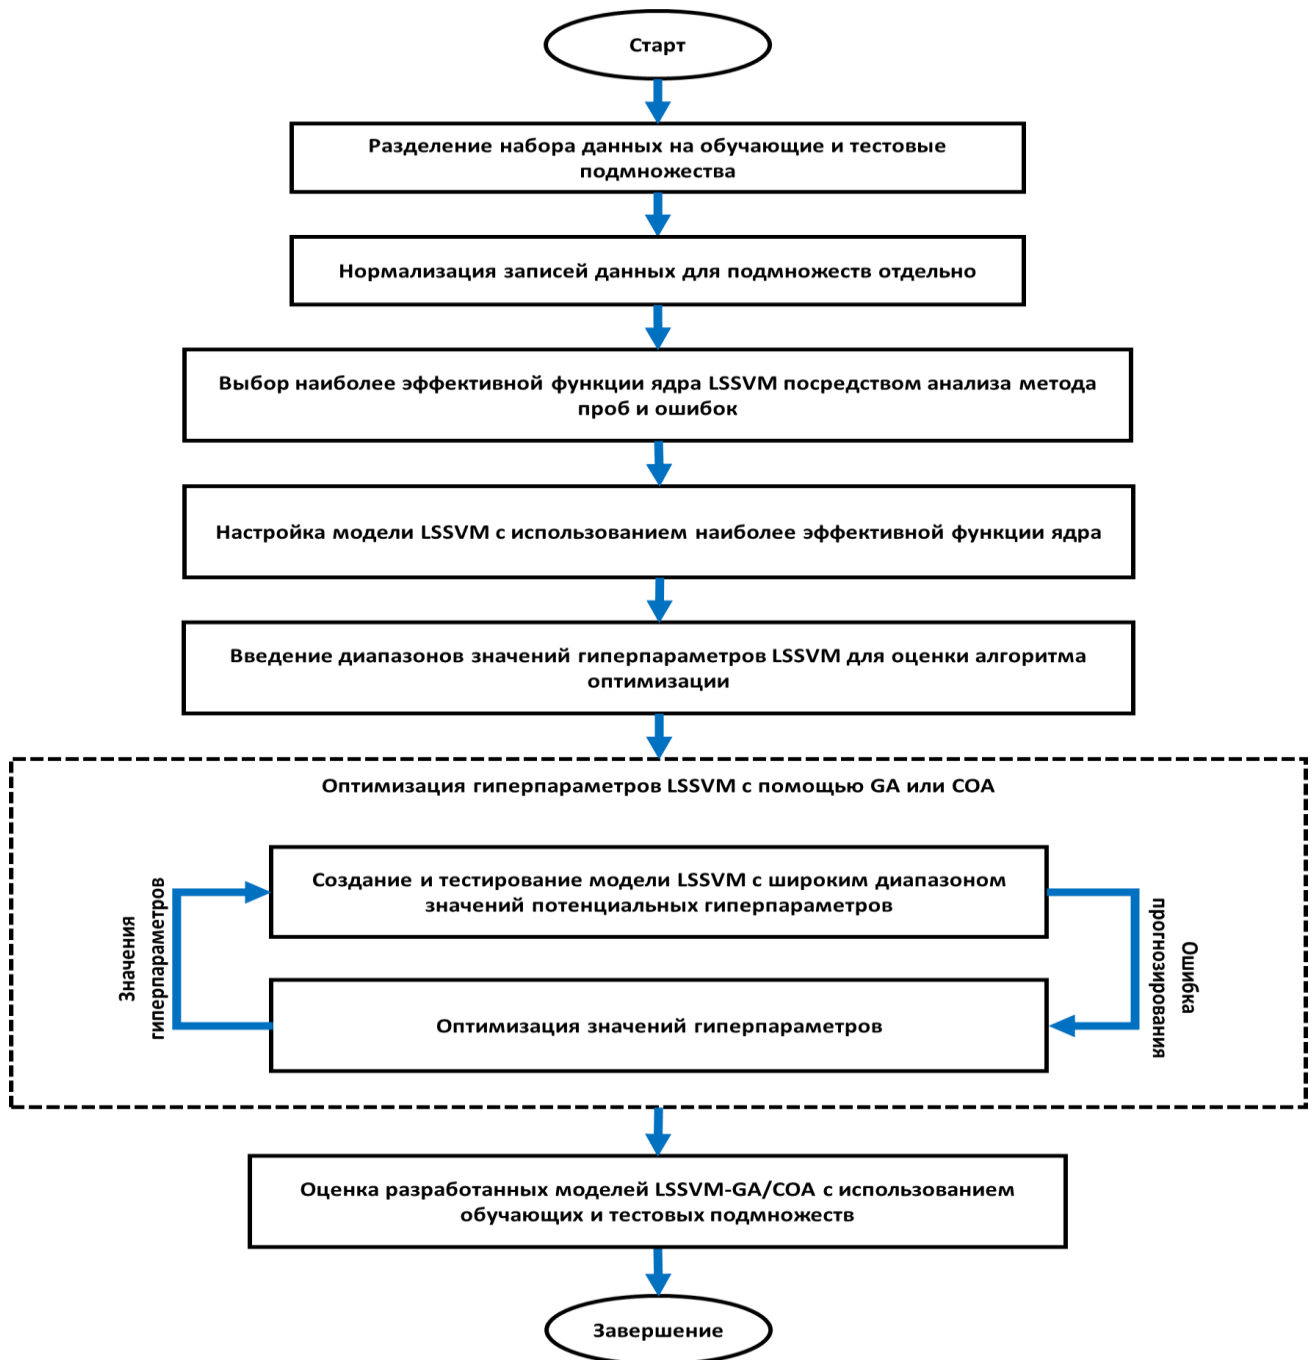


Рисунок 2.6 – Схема реализации гибридных моделей LSSVM–GA/COA (Машина опорных векторов наименьших квадратов, оптимизированная генетическим алгоритмом или и алгоритмом оптимизации Cuckoo), разработанных для прогнозирования реологических и фильтрационных свойств буровых растворов.

Псевдокоды гибридных прогнозных моделей LSSVM/GA и MELM/GA представлены ниже:

Псевдокод для модели LSSVM-COA

LSSVM-COA

Inputs

X_{train} : Training data with N_p features(rows) and N_{train} samples(columns)

Y_{train} : Training target vector of length N_{train}

X_{test} : Test data with N_p features(rows) and N_{test} samples(columns)

Y_{test} : Training target vector of length N_{test}

N_p : number of parameters to be optimized

N_c : initial number of cuckoos

$MAX_{CUCKOOS}$: maximum number of cuckoos at the same time

MIN_{EGGS} : minimum number of eggs for each cuckoo

MAX_{EGGS} : maximum number of eggs for each cuckoo

N_{iter} : maximum number of iterations in the algorithm

K : number of clusters in *kmeans* algorithm

λ : percent of flight distance for cuckoos

α : control parameter of egg laying

δ : population variance that cuts the optimization

LB: lower bound of the parameters

UB: upper bound of the parameters

outputs

γ : regularization parameter of the LSSVM method

σ : Radial Basis Function (RBF) kernel width

▷ the symble (▷) is used for comments

▷ $Cat(A, B)$ gets matrix $A_{w \times y}$ and matrix $B_{w \times z}$ and returns a matrix $C_{w \times q}$ where $q = y + z$

▷ $Zeros(A, B)$ returns a matrix with A rows and B columns with all entries set to zero

▷ $Random(S, [B, C])$ returns a uniformly random generated vector of values $\in [B, C]$ and length S

▷ $Sign(x) = \begin{cases} +1 & x \geq 0 \\ -1 & x < 0 \end{cases}$

▷ $\lfloor \cdot \rfloor$ is the floor function

▷ $argmin(A)$ returns the index of the smallest value in vector A

▷ $argsort(A)$ returns the index of values in vector A in ascending order

▷ $Kmeans(positions, K)$ return a list of length equal to number of points in positions matrix where

▷ i th entry entry specifies the cluster number of the corresponding point in i th column of positions

1 $globalBest \leftarrow$ empty vector

2 $globalBestCost \leftarrow +\infty$

▷ initialize egg laying center for each cuckoo

3 **for** $i \leftarrow 1 \dots N_c$ **do**

4 $cuckoo[i].center \leftarrow Random(N_p, [LB, UB])$

5 **end for**

6 **for** $iteration \leftarrow 1 \dots N_{iter}$ **do**

7 $sumEggs \leftarrow 0$

8 ▷ set the number of eggs for each cuckoo and accumelate total number of eggs

9 **for** $i \leftarrow 1 \dots N_c$ **do**

10 $cuckoo[i].numEggs \leftarrow \lfloor Random(1, [MIN_{EGGS}, MAX_{EGGS}]) \rfloor$

11 $sumEggs \leftarrow sumEggs + cuckoo[i].numEggs$

12 **end for**

▷ Calculate Egg Laying Redius for each cuckoo

13 **for** $i \leftarrow 1 \dots N_c$ **do**

14 $cuckoo[i].ELR \leftarrow cuckoo[i].numEggs/sumEggs \times \alpha \times (UB - LB)$

15 **end for**

▷ each cuckoo layes its eggs by dividing a (hyper)circle to equal segments

```

16   $\triangleright$  to search all over the current habitat
17  for  $i \leftarrow 1 \dots N_c$  do
18       $params \leftarrow cuckoo[i].center$ 
19       $angle \leftarrow 0$ 
20      for  $j \leftarrow 1 \dots cuckoo[i].numEggs$  do
21           $r \leftarrow Random(1, [0 \dots 1]) \times cuckoo[i].ELR$ 
22          for  $k \leftarrow 1 \dots N_p$  do
23               $d \leftarrow sign(Random(1, [-1, 1]))$ 
24               $\triangleright$  eggs[k,j] is the kth parameter of the jth egg
25               $cuckoo[i].eggs[k,j] \leftarrow params[k] + d \times (r \times \cos(angle) + r \times \sin(angle))$ 
26               $\triangleright$  boundry check
27               $cuckoo[i].eggs[k,j] \leftarrow \min(\max(cuckoo[i].eggs[j,k], LB), UB)$ 
28          end for
29           $angle \leftarrow angle + (2 \times \pi)/(cuckoo[i].numEggs)$ 
30      end for
31  end for
32   $\triangleright$  put all of the centers and eggs in a single positions matrix to evaluate
33   $positions \leftarrow$  empy matrix
34   $cost \leftarrow Zeros(N_c + sumEggs, 1)$ 
35  for  $i \leftarrow 1 \dots N_c$  do
36       $positions \leftarrow Cat(positions, cuckoo[i].center)$ 
37       $positions \leftarrow Cat(positions, cuckos[i].eggs)$ 
38  end for
39  for  $i \leftarrow 1 \dots (N_c + sumEggs)$  do
40       $\gamma, \sigma \leftarrow positions[:, i]$   $\triangleright$  the ith column of the matrix
41       $cost[i] \leftarrow train\_and\_evaluate\_LSSVM(X_{train}, Y_{train}, X_{test}, Y_{test}, \gamma, \sigma)$ 
42  end for
43   $\triangleright$  update the best solution so far if necessary
44   $minIndex \leftarrow argmin(cost)$ 
45  if  $cost[minIndex] < globalBestCost$  then
46       $globalBestCost \leftarrow cost[minIndex]$ 
47       $globalBest \leftarrow positions[:, minIndex]$ 
48  end if
49   $\triangleright$  if total number of eggs and cuckoos exceeds the limit, delete the worst
50   $\triangleright$  performing ones
51  if  $N_c + sumEggs > MAX_{cuckoos}$  then
52       $sortIndex \leftarrow argsort(cost)$ 
53       $cost \leftarrow cost[sortIndex]$   $\triangleright$  sort cost values from smallest to the largest
54       $positions \leftarrow positions[:, sortIndex]$   $\triangleright$  sort positions according their cost
55       $N_c \leftarrow MAX_{cuckoos}$ 
56       $positions \leftarrow positions[:, 1 \dots N_c]$   $\triangleright$  retain only the best  $N_c$  solutions
57  end if
58   $\triangleright$  use kmean clustering method to group cuckoos into K distictive groups
59   $clusterNumberIndex \leftarrow Kmeans(positions, K)$ 
60   $\triangleright$  calculate the average cost for each cluster
61   $clusterMean \leftarrow Zeros(K, 1)$ 
62   $clusterMemberCounter \leftarrow Zeros(K, 1)$ 
63   $numberOfPositions \leftarrow Size(positions, 2)$ 
64  for  $i \leftarrow 1 \dots numberOfPositions$  do
65       $j \leftarrow clusterIndex[i]$ 
66       $clusterMean[j] \leftarrow clusterMean[j] + cost[j]$ 
67       $clusterMemberCounter[j] \leftarrow clusterMemberCounter[j] + 1$ 
68  end for
69  for  $i \leftarrow 1 \dots K$  do
70       $clusterCostAverage[i] \leftarrow clusterCostAverage[i]/clusterMemberCounter[i]$ 

```

```

62  end for
    ▷ find the best performing cuckoo (goal point) in the best cluster
63   $bestClusterIndex \leftarrow \operatorname{argmin}(\operatorname{clusterCostAverage})$ 
64   $goalPositionCost \leftarrow +\infty$ 
65  for  $i \leftarrow 1 \dots \operatorname{numberOfPositions}$  do
66       $j \leftarrow \operatorname{clusterIndex}[i]$ 
67      if  $(j = bestClusterIndex)$  and  $goalPositionCost > \operatorname{cost}[j]$  then
68           $goalPositionCost \leftarrow \operatorname{cost}[j]$ 
69           $goalPoint \leftarrow \operatorname{positions}[:, i]$ 
70      end if
71  end for
    ▷ move all of the cuckoos towards the goal point and calculate their cost
72   $cost \leftarrow \operatorname{Zeros}(\operatorname{numberOfPositions}, 1)$ 
73  for  $i \leftarrow 1 \dots \operatorname{numberOfPositions}$  do
74      ▷.* is elementwise mutplication
       $d \leftarrow (\operatorname{goalPoint} - \operatorname{positions}[:, i]) .* \operatorname{Random}(N_p, [0,1])$ 
75       $\operatorname{positions}[:, i] \leftarrow \operatorname{positions}[:, i] + d$ 
      ▷ elementwise min and max
76       $\operatorname{positions}[:, i] \leftarrow \min(\max(\operatorname{positions}[:, i], \mathbf{LB}), \mathbf{UB})$ 
77       $\gamma, \sigma \leftarrow \operatorname{positions}[:, i]$ 
78       $\operatorname{cost}[i] \leftarrow \operatorname{train\_and\_evaluate\_LSSVM}(X_{train}, Y_{train}, X_{test}, Y_{test}, \gamma, \sigma)$ 
79  end for
    ▷ check and update (if necessary) the best cuckoo (solution) so far
80   $\operatorname{sortIndex} \leftarrow \operatorname{argsort}(cost)$ 
81   $cost \leftarrow \operatorname{cost}[\operatorname{sortIndex}]$ 
82   $\operatorname{positions} \leftarrow \operatorname{positions}[:, \operatorname{sortIndex}]$ 
83  if  $\operatorname{cost}[1] < \operatorname{globalBestCost}$  then
84       $\operatorname{globalBestCost} \leftarrow \operatorname{cost}[1]$ 
85       $\operatorname{globalBest} \leftarrow \operatorname{positions}[:, 1]$ 
86  end if
    ▷ replace the worst performing cuckoo with the best cuckoo to let the best
    ▷ to live beyond generations
87   $\operatorname{positions}[:, \operatorname{numberOfPositions}] \leftarrow \operatorname{globalBest}$ 
    ▷ replace the second worst performing cuckoo with a variant of the best cuckoo
88   $\operatorname{positions}[:, \operatorname{numberOfPositions} - 1] \leftarrow \operatorname{Random}(N_p, [0,1]) .* \operatorname{globalBest}$ 
89  end for
90   $\gamma, \sigma \leftarrow \operatorname{globalBest}$ 
91  return  $\gamma, \sigma$ 

```

Псевдокод *train_and_evaluate_LSSVM*

Inputs

X_{train} : Training data with N_p features(rows) and N_{train} samples(columns)
 Y_{train} : Training target vector of length N_{train}
 X_{test} : Test data with N_p features(rows) and N_{test} samples(columns)
 Y_{test} : Training target vector of length N_{test}
 γ : Regularization parameter
 σ : Kernel width parameter

Output

RMSE: Root Mean Squared Error for test data

▷ Compute the kernel matrix K_{Train} for the training data using the RBF kernel

```

1   $K_{Train} \leftarrow \operatorname{Zeros}(N_{train}, N_{train})$ 
2  for  $i \leftarrow 1 \dots N_{train}$  do

```

```

3   |   for  $j \leftarrow 1 \dots N_{train}$  do
4   |       |  $KTrain[i, j] \leftarrow \exp\left(-\frac{norm(X_{train}[i] - X_{train}[j])}{2 * \sigma^2}\right)$ 
5   |   end for
6   end for
7    $\triangleright$  Compute the kernel matrix  $KTest$  for the test data using the RBF kernel
8    $KTest \leftarrow Zeros(N_{test}, N_{train})$ 
9   for  $i \leftarrow 1 \dots N_{test}$  do
10  |   for  $j \leftarrow 1 \dots N_{train}$  do
11  |       |  $KTest[i, j] \leftarrow \exp\left(-\frac{norm(X_{test}[i] - X_{train}[j])}{2 * \sigma^2}\right)$ 
12  |   end for
13  end for
14   $\triangleright$  Compute the solution  $\alpha$  by solving the optimization problem
15   $H \leftarrow KTrain + (1/\gamma) \times I$     $\triangleright$   $I$  is the identity matrix
16   $\alpha \leftarrow H^{-1} \times Y_{train}$ 
17   $Y_{pred} \leftarrow KTest \times \alpha$ 
18   $\triangleright$  Compute Root Mean Squared Error
19   $rmse \leftarrow \sqrt{\frac{1}{N_{test}} \sum_i^{N_{test}} (Y_{test}[i] - Y_{pred}[i])^2}$ 
20  return  $rmse$ 

```

Псевдокод для модели LSSVM-GA

LSSVM-GA

Inputs

X_{train} : Training data with N_p features(rows) and N_{train} samples(columns)
 Y_{train} : Training target vector of length N_{train}
 X_{test} : Test data with N_p features(rows) and N_{test} samples(columns)
 Y_{test} : Training target vector of length N_{test}
 N_p : number of parameters to be optimized
 N_c : initial number of chromosomes (solutions)
 N_{iter} : maximum number of iterations in the algorithm
 P_c : crossover (reproduction) percentage
 P_m : mutation percentage
 γ : crossover coefficient parameter range
 μ : mutation rate
 β : selection pressure
 LB : lower bound of the parameters
 UB : upper bound of the parameters

outputs

γ : regularization parameter of the LSSVM method
 σ : Radial Basis Function (RBF) kernel width

- \triangleright the symble (\triangleright) is used for comments
- \triangleright $Cat(A, B)$ gets matrix $A_{w \times y}$ and matrix $B_{w \times z}$ and returns a matrix $C_{w \times q}$ where $q = y + z$
- \triangleright $Zeros(A, B)$ returns a matrix with A rows and B columns with all entries set to zero
- \triangleright $Random(p, q, [B, C])$ returns a uniformly random generated $p \times q$ matrix of values $\in [B, C]$
- \triangleright $RandomN(p, q, [B, C])$ returns a $p \times q$ matrix of values $\in [B, C]$ sampled from normal distribution
- \triangleright $\lfloor \cdot \rfloor$ is the floor function
- \triangleright $argmin(A)$ returns the index of the smallest value in vector A
- \triangleright $argsort(A)$ returns the index of values in vector A in ascending order

1 $numX \leftarrow 2 \times \lfloor P_c \times N_c / 2 \rfloor$

```

3  numM ←  $\lfloor P_m \times N_c \rfloor$ 
   ▷ initialize the population with random values where each column of pop is a solution
3  pop ← Random( $N_p, N_c, [LB, UB]$ )
   ▷ evaluate the chromosomes
4  cost ← Zeros( $N_c, 1$ )
5  for i ← 1 ...  $N_c$  do
6       $\gamma, \sigma \leftarrow pop[:, i]$            ▷ the ith column of the matrix
7      cost[i] ← train_and_evaluate_LSSVM( $X_{train}, Y_{train}, X_{test}, Y_{test}, \gamma, \sigma$ )
8  end for
   ▷ find the best solution of initial populatio
9  bestIndex ← argmin(cost)
10 globalBest ← pop[:, bestIndex]
11 globalBestCost ← cost[bestIndex]
   ▷ iterate for  $N_c$  iterations
11 for iteration ← 1 ...  $N_{iter}$  do
   ▷ calculate selection chance for each chromosome based of their cost and make
   ▷ cumulative sum array
12  p = Zeros( $N_c, 1$ )
13  sumP ← 0
14  for i ← 1 ...  $N_c$  do
15      |  $p[i] \leftarrow sumP + e^{-\beta \times cost[i]}$ 
16      |  $sumP \leftarrow sumP + p[i]$ 
17  end for
   ▷ normalize chances to be probabilities
18  for i ← 1 ...  $N_c$  do
19      |  $p[i] \leftarrow p[i]/sumP$ 
20  end for
   ▷ create crossover population
21  popX ← Zeros( $N_p, numX$ )
22  costX ← Zeros(1, numX)
23  i ← 1
24  while i < numX do
   ▷ select first parent for crossover
25      r ← Random(1, 1, [0, 1])
26      parent1Index ← 1
27      while r > p[parent1Index] do
28          | parent1Index ← parent1Index + 1
29      end while
   ▷ select second parent for crossover
30      r ← Random(1, 1, [0, 1])
31      parent2Index ← 1
32      while r > p[parent2Index] do
33          | parent2Index ← parent2Index + 1
34      end while
   ▷ crossover
35      for j ← 1 ...  $N_p$  do
36          |  $\alpha \leftarrow Random(1, 1, [-\gamma, 1 + \gamma])$ 
37          |  $popX[j, i] \leftarrow \alpha \times pop[j, parent1Index] + (1 - \alpha) \times pop[j, parent2Index]$ 
38          |  $popX[j, i + 1] \leftarrow \alpha \times pop[j, parent2Index] + (1 - \alpha) \times pop[j, parent1Index]$ 
   ▷ check for boundry violations
39          |  $popX[j, i] \leftarrow \min(\max(popX[j, i], LB), UB)$ 
40          |  $popX[j, i + 1] \leftarrow \min(\max(popX[j, i + 1], LB), UB)$ 
41      end for
   ▷ evaluate the new offsprings
42       $\gamma, \sigma \leftarrow popX[:, i]$ 

```

```

43   | costX[i] ← train_and_evaluate_LSSVM( $X_{train}, Y_{train}, X_{test}, Y_{test}, \gamma, \sigma$ )
44   |  $\gamma, \sigma \leftarrow popX[:, i + 1]$ 
45   | costX[i + 1] ← train_and_evaluate_LSSVM( $X_{train}, Y_{train}, X_{test}, Y_{test}, \gamma, \sigma$ )
46   |  $i \leftarrow i + 2$ 
47   end while
    ▷ create mutation population
48   popM ← Zeros( $N_p, num_M$ )
49   costM ← Zeros(1, numM)
50   mutationRange ←  $0.1 \times (UB - LB)$ 
51   for  $i \leftarrow 1 \dots numM$  do
    ▷ select and mutate a chromosome
52   indexM ← [Random(1, 1, [1,  $N_c$ ])]
53   for  $j \leftarrow 1 \dots N_p$  do
54   |  $r \leftarrow Random(1, 1, [0, 1])$ 
55   | if  $r \leq \mu$  then
56   | |  $popM[j, i] \leftarrow pop[j, indexM] + mutationRange \times RandomN(1, 1)$ 
57   | else
58   | |  $popM[j, i] \leftarrow pop[j, indexM]$ 
59   | end if
    ▷ evaluate the new chromosome
60   |  $popM[j, i] \leftarrow \min(\max(popM[j, i], LB), UB)$ 
61   end for
62    $\gamma, \sigma \leftarrow popM[:, i]$ 
63   costM[i] ← train_and_evaluate_LSSVM( $X_{train}, Y_{train}, X_{test}, Y_{test}, \gamma, \sigma$ )
64   end for
    ▷ concatenate all populations and sort them based on their cost
65   pop ← Cat(pop, popX)
66   pop ← Cat(pop, popM)
67   cost ← Cat(cost, costX)
68   cost ← Car(cost, costM)
69   sortOrder ← argsort(cost)
70   pop ← pop[:, sortOrder]
71   cost ← cost[sortOrder]
    ▷ retain only the  $N_c$  best chromosomes
72   pop ← pop[:, 1 ...  $N_c$ ]
73   cost ← cost[:, 1 ...  $N_c$ ]
    ▷ update the global best
74   if  $globalBestCost > cost[1]$  then
75   |  $globalBest \leftarrow pop[:, 1]$ 
76   |  $globalBestCost \leftarrow cost[1]$ 
74   end if
75   end for
76    $\gamma, \sigma \leftarrow globalBest$ 
77   return  $\gamma, \sigma$ 

```

Псевдокод _and_evaluate_LSSVM

Inputs

X_{train} : Training data with N_p features(rows) and N_{train} samples(columns)
 Y_{train} : Training target vector of length N_{train}
 X_{test} : Test data with N_p features(rows) and N_{test} samples(columns)
 Y_{test} : Training target vector of length N_{test}
 γ : Regularization parameter
 σ : Kernel width parameter

Output

| *RMSE: Root Mean Squared Error for test data*

▷ *Compute the kernel matrix KTrain for the training data using the RBF kernel*

```

1 KTrain ← Zeros( $N_{train}, N_{train}$ )
2 for  $i \leftarrow 1 \dots N_{train}$  do
3   for  $j \leftarrow 1 \dots N_{train}$  do
4      $KTrain[i, j] \leftarrow \exp\left(-\frac{\text{norm}(X_{train}[i] - X_{train}[j])}{2 * \sigma^2}\right)$ 
5   end for
6 end for

```

▷ *Compute the kernel matrix KTest for the test data using the RBF kernel*

```

7 KTest ← Zeros( $N_{test}, N_{train}$ )
8 for  $i \leftarrow 1 \dots N_{test}$  do
9   for  $j \leftarrow 1 \dots N_{train}$  do
10     $KTest[i, j] \leftarrow \exp\left(-\frac{\text{norm}(X_{test}[i] - X_{train}[j])}{2 * \sigma^2}\right)$ 
11  end for
12 end for

```

▷ *Compute the solution alpha by solving the optimization problem*

```

13  $H \leftarrow KTrain + (1/\gamma) \times I$  ▷ I is the identity matrix
14  $alpha \leftarrow H^{-1} \times Y_{train}$ 
15  $Y_{pred} \leftarrow KTest \times alpha$ 

```

▷ *Compute Root Mean Squared Error*

```

16  $rmse \leftarrow \sqrt{\frac{1}{N_{test}} \sum_i^{N_{test}} (Y_{test}[i] - Y_{pred}[i])^2}$ 
17 return rmse

```

2.6. Последовательность действий

На рисунке 2.8 приведена диаграмма, раскрывающая методологию, используемую для прогнозирования реологических и фильтрационных свойств буровых растворов на водной основе.

Результаты полевых измерений параметров буровых растворов, как правило, содержат некоторое количество ошибочных значений. Такие значения могут быть результатом как плохо откалиброванного измерительного оборудования, так и человеческого фактора. В этой связи в ходе предварительной обработки набора данных по буровому раствору до начала моделирования необходимо отфильтровывать ошибочные записи. В первую очередь была проведена предварительная обработка скомпилированного набора данных с использованием расстояния Махаланобисовского (MD) в сочетании с результатами прогноза

алгоритма гауссового процесса регрессии (ГП) для обнаружения выбросов (см. раздел 3.2.3.) и обоснования их устранения.

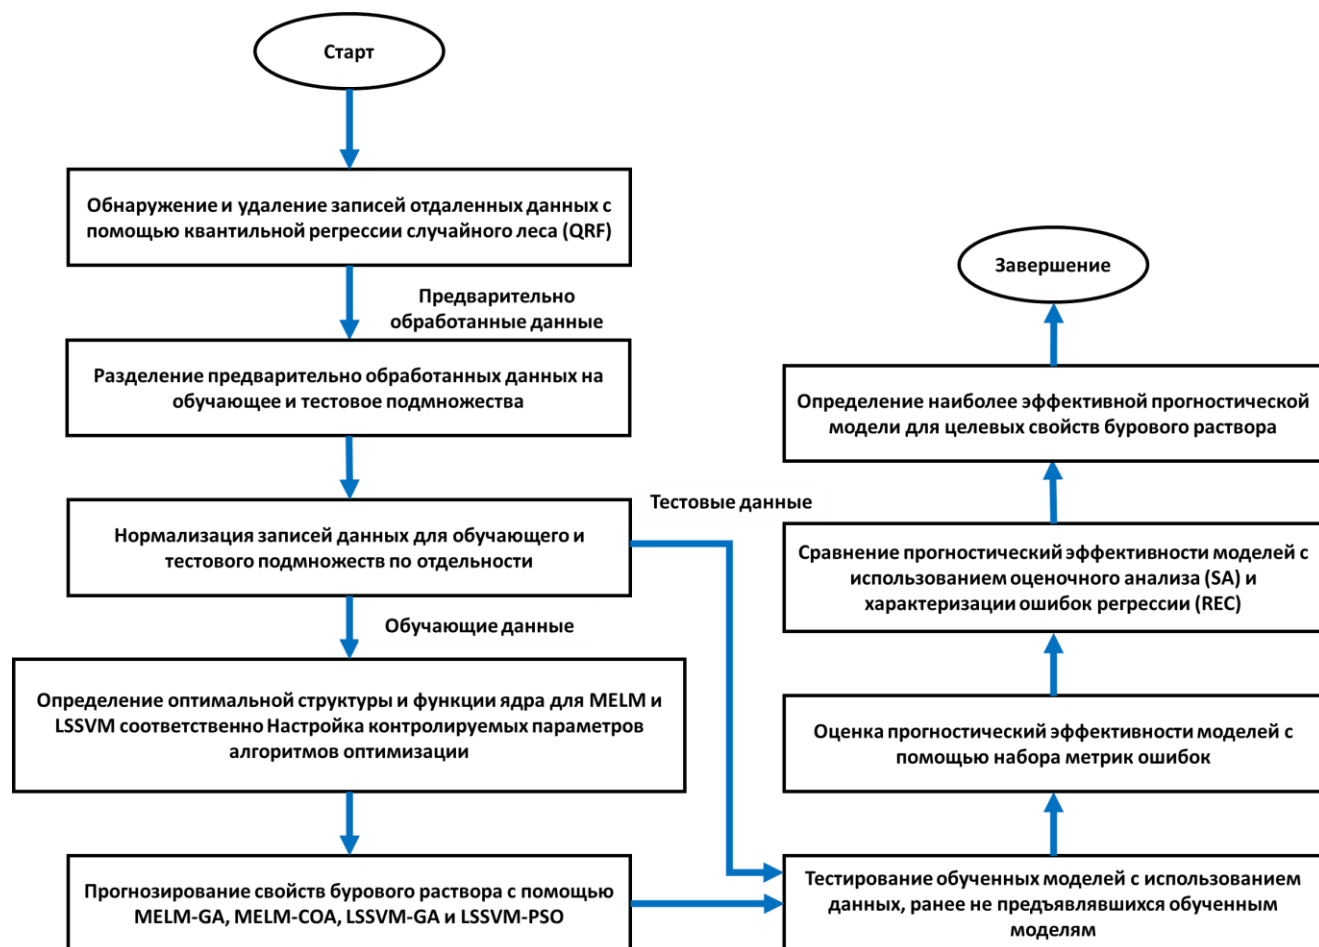


Рисунок 2.7 – Последовательность действий при прогнозировании реологических и фильтрационных свойств буровых растворов на водной основе с помощью гибридной модели МО.

Отсеянные и сохраненные записи были разделены на два подмножества: одно для обучения модели (80% от общего числа записей) и одно для тестирования модели (20% от общего числа записей). Затем обучающие и тестовые подмножества были отдельно нормализованы с использованием следующего уравнения для масштабирования всех переменных до диапазона от +1 до -1:

$$Normx_i^l = \left(\frac{x_i^l - xmin^l}{xmax^l - xmin^l} \right) \cdot 2 - 1, \quad (2.27)$$

где x_i^l означает зарегистрированное значение переменной l для записи i ; $xmax^l$ а $xmin^l$ означают, соответственно, максимум и минимум зарегистрированных

значений переменной l . Далее контролируемые гибридные модели МО (MELM–COA (многопользовательская экстремальная обучающая машина, оптимизированная алгоритмом Cuckoo, MELM–GA, LSSVM–COA (машина опорных векторов наименьших квадратов, оптимизированная алгоритмом Cuckoo и LSSVM–GA) были обучены с использованием обучающего подмножества, для которого было проведено несколько запусков и статистически оценены результаты для установления прогнозных характеристик моделей в отношении целевых параметров бурового раствора. Обобщаемая способность обученных моделей гибридных МО проверялась независимо путем применения обученных моделей к отдельному подмножеству записей данных (тестовому подмножеству), ранее не предъявлявшемуся обученным моделям. Далее была проведена оценка производительности моделей по пяти показателям статистической погрешности (раздел 2.4). Путем применения двух дополнительных оценок эффективности прогнозирования, а именно, оценочного анализа (SA) и характеристики ошибок регрессии (REC), была выявлена наиболее эффективная гибридная модель МО в части прогнозирования целевых параметров бурового раствора (раздел 2.4).

ГЛАВА 3. Эксперименты, проведенные для разработки прогнозных моделей

3.1. Оценка корреляций между зависимыми и независимыми переменными

Коэффициенты корреляции между тремя входными параметрами ($\rho_{бр}$, УВ и ТФ) и каждой из зависимых переменных (Ф, ПВ, ДНС) представлены в виде HeatMap–графика (рисунок 3.1).




Рисунок 3.1 – График тепловой карты коэффициентов корреляции (r) между изучаемыми свойствами бурового раствора.

На карте корреляций высокие значения положительных корреляций выделены красным цветом, а высокие значения отрицательных – синим. ПВ и ДНС демонстрируют положительные корреляции со всеми тремя входными признаками. Это означает, что с увеличением значений переменных $\rho_{бр}$, УВ и ТФ увеличиваются значения ДНС и ПВ. Такой высокий уровень корреляции можно объяснить тем, что в процессе бурения, по мере продвижения буровых долот вглубь недр, они встречают пласты с более высоким давлением, чем в приповерхностных пластах. Для борьбы с этими более высокими давлениями в буровые растворы добавляются различные утяжелители, такие как барит, гематит, ильменит, частицы карбоната

кальция, которые придают им достаточно высокую плотность. Чем выше содержание твердых частиц (утяжелителей), тем больше плотность бурового раствора [12,105]. ТФ и $\rho_{бр}$ также имеют прямую сильную положительную корреляцию друг с другом и аналогичным образом влияют на реологические свойства буровых растворов (ПВ и ДНС). При этом наиболее сильную положительную корреляцию с ПВ и ДНС демонстрирует $\rho_{бр}$. Пирозян и др. [162] отметили, что увеличение ТФ в буровых растворах приводит к увеличению ПВ растворов, причем такое улучшение реологии буровых растворов объясняется наличием мостиковой сети, образованной твердыми частицами добавленных утяжелителей [163,164]. УВ имеет несколько более слабую положительную корреляцию с ПВ по сравнению с ТФ и плотностью.

Напротив, три входные переменные демонстрируют обратную корреляцию от водоотдачи. Наиболее слабая и сильная корреляции со значениями водоотдачи наблюдаются у условной вязкости и плотности соответственно. Высокое значение отрицательной корреляции между условной вязкостью и водоотдачей обусловлено присутствием полимеров и других добавок, таких как бентонит, которые обеспечивают вязкость буровых растворов. Наличие таких материалов в буровых растворах также приводит к образованию жестких полимерных связей между твердыми частицами, формирующими глинистую корку на стенках ствола скважины, что значительно снижает проницаемость глинистой корки. Чем ниже проницаемость глинистой корки, тем ниже объем фильтрата бурового раствора, проникающего в пласт [165]. В результате между вязкостью и водоотдачей существует сильная отрицательная корреляционная связь. Это означает, что при увеличении вязкости бурового раствора, водоотдача будет снижаться, и наоборот, при снижении вязкости водоотдача будет возрастать. Отношения, описывающие типы корреляции между входными переменными и каждой зависимой переменной, выражены следующими уравнениями:

$$\Phi \in \frac{1}{(\rho_{бр}, УВ, ТФ)}, \quad (3.1)$$

$$ПВ \in p_{бр}, УВ, ТФ, \quad (3.2)$$

$$ДНС \in p_{бр}, УВ, ТФ. \quad (3.3)$$

3.2. Обработка данных

3.2.1. Разделение данных для обучения и тестирования

Правильное разделение данных является ключевым для разработки эффективных моделей машинного обучения. Набор данных должен быть разделен на обучающие и тестовые подмножества. Модель обучается на обучающих данных, а затем оценивается на тестовых данных. Обычно для обучения выделяют 60–80% данных, а оставшиеся 20–40% – для тестирования, хотя оптимальные пропорции зависят от размера набора данных и его изменчивости. Разделение должно быть случайным, чтобы обеспечить репрезентативное выборочное исследование. Для небольших наборов данных предпочтительны подходы кросс-валидации, которые используют вращение подмножеств для обучения и тестирования, вместо единичного разделения на обучение и тестирование. Тестовый набор данных используется исключительно для окончательной оценки модели, а не для настройки параметров, чтобы приблизить эффективность на основе новых данных. Тщательное разделение данных обеспечивает объективную подгонку и оценку моделей.

В данном исследовании оптимальное соотношение обучающих и тестовых данных было определено с использованием метода проб и ошибок. Данные были случайным образом разделены на различные пропорции 60/40, 70/30 и 80/20 для обучения и тестирования. Затем метод LSSVM с ядром RBF был применен к обучающим данным. Для снижения возможного влияния случайной вариации данных на результаты оценки был использован метод 10-кратной кросс-валидации. Для оценки применимости обученных моделей они были опробованы на тестовых данных для определения их обобщающей способности. На рисунке 3.2 показано сравнение среднеквадратичного отклонения (RMSE) на этапах обучения и тестирования моделей, созданных с помощью LSSVM при различных

соотношениях обучающих и тестовых данных (60/40, 70/30 и 80/20) для прогнозирования Φ , ПВ и ДНС.

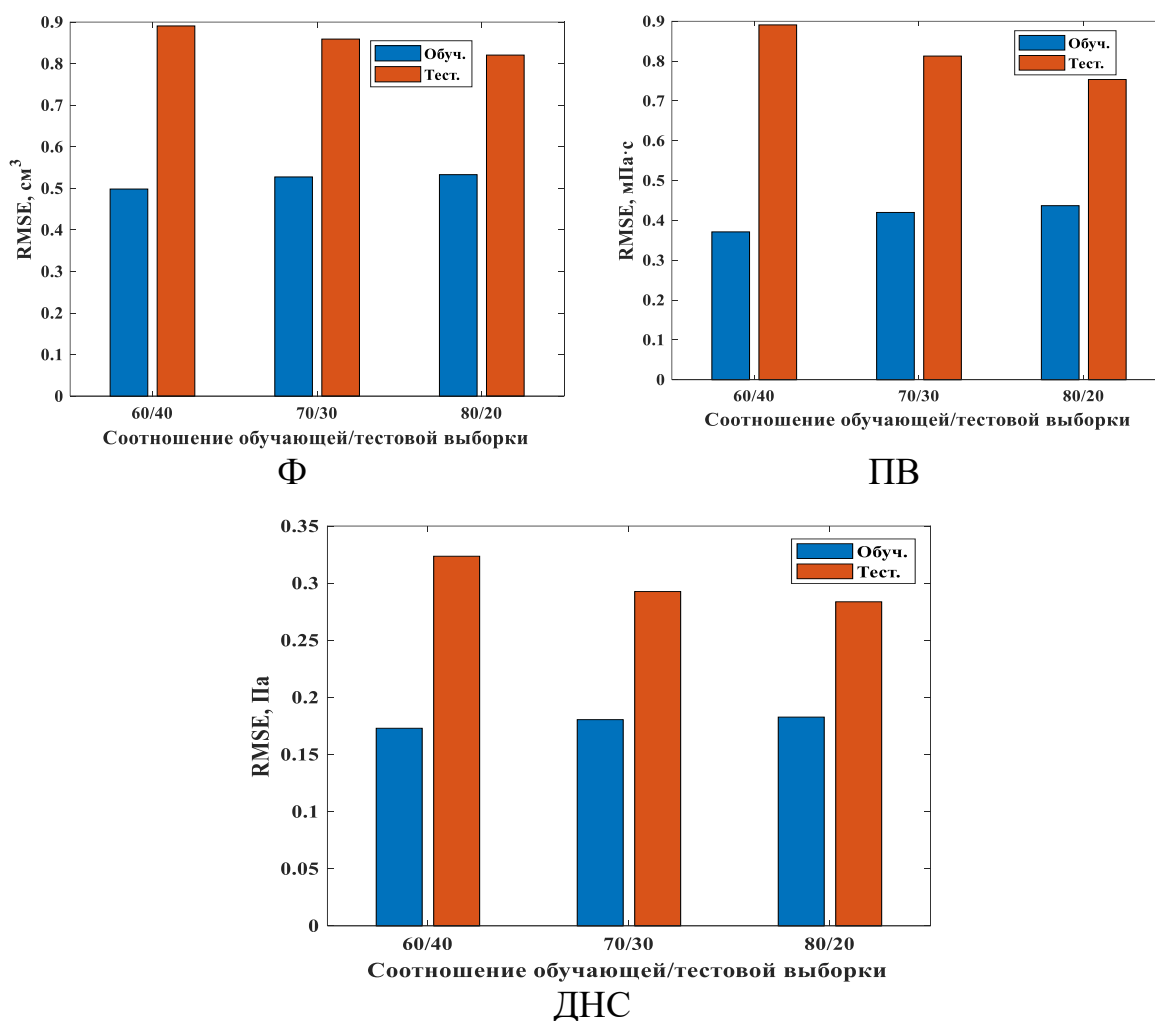


Рисунок 3.2 – Сравнение среднеквадратичного отклонения (RMSE) моделей, созданных с помощью LSSVM с ядром RBF на этапах обучения и тестирования при различных соотношениях обучающих и тестовых данных для прогнозирования Φ , ПВ и ДНС.

На рисунке 3.2 показано сравнение среднеквадратичного отклонения (RMSE) на этапах обучения и тестирования моделей, созданных с помощью LSSVM при различных соотношениях обучающих и тестовых данных (60/40, 70/30 и 80/20) для прогнозирования Φ , ПВ и ДНС. Как видно из этого рисунка, ошибка на этапе обучения также увеличивается с увеличением объема обучающих данных. В то же время ошибка на этапе тестирования уменьшается при уменьшении объема тестовых данных. Учитывая, что увеличение ошибки на этапе обучения менее

значимо по сравнению с уменьшением ошибки на этапе тестирования, и учитывая также высокую важность способности обобщения модели на невидимых данных, пропорция 80/20 обучающих и тестовых данных, по сравнению с двумя другими пропорциями, является наиболее подходящей для разделения данных в данном исследовании.

3.2.2. Нормализация данных

Нормализация данных — это важная техника предварительной обработки для разработки эффективных моделей машинного обучения [159]. Путем масштабирования параметров так, чтобы они имели схожие диапазоны, нормализация обеспечивает более эффективное обучение модели, избегает предвзятости от параметров с большими масштабами, предотвращает насыщение эффектов в нелинейных моделях, возникающее при очень больших значениях входных данных или весов модели, улучшает устойчивость и обобщение модели [160]. Конкретно, нормализация помещает все параметры в общий диапазон, облегчая более быструю сходимость алгоритмов оптимизации, используемых для обучения [160]. Без нормализации некоторые параметры могут иметь значения, отличающиеся на несколько порядков, что усложняет ландшафт оптимизации и затрудняет обучение [159]. Кроме того, параметры с большими масштабами значений могут доминировать в целевой функции, что приводит к моделям, просто воспроизводящим эти параметры, вместо изучения смысловых взаимосвязей между ними [160]. Нормализация предотвращает такие эффекты доминирования. Кроме того, многие модели машинного обучения, такие как нейронные сети, используют нелинейные функции активации, которые насыщаются для больших значений входных данных [160]. Путем поддержания нормализованных входных данных избегается насыщение на ранних итерациях обучения, что обеспечивает более эффективное обучение. Наконец, модели, обученные на основе нормализованных данных, более устойчивы к различиям в масштабе и распределению между обучающими и тестовыми данными, что улучшает обобщение [159].

Существует несколько методов нормализации данных, таких как Z-score, Min-Max и логарифмическое масштабирование. Каждый из этих методов имеет свои достоинства и недостатки. Однако, так как цель заключается исключительно в приведении значений данных к схожему диапазону, в данном исследовании будет использован метод Min-Max нормализации. Таким образом, Min-Max нормализация, которая масштабирует все параметры в фиксированный диапазон от -1 до 1, подходит для этой цели. После разделения данных на обучающую и тестовую выборки, нормализация данных была применена индивидуально к каждой из них.

3.2.3. Выявление и устранение выбросов

Выбросы — это величины, которые значительно отличаются от большинства значений выборки и могут быть результатом как ошибок измерения, так и ошибок ввода данных или физических аномалий данных. Невозможно избежать таких ошибок при сборе данных, и даже с применением строгих мер контроля, наборы данных могут содержать до 5% таких ошибок. Когда модели машинного обучения обучаются на наборах данных, содержащих выбросы, эти выбросы могут исказить шаблоны и взаимосвязи, полученные моделями из данных. В результате модели могут недостоверно отображать основное распределение данных, что приводит к ненадлежащей интерпретируемости и производительности на тестовых данных. Это ограничивает их полезность в реальных сценариях. Поэтому важно выявлять и удалять выбросы из наборов данных перед обучением моделей МО. Это позволит моделям основываясь на точных и надежных данных предоставлять значимые и точные прогнозы и выводы. В данном исследовании была использована регрессия на основе гауссовских процессов (ГП) для разработки модели прогнозирования Ф, ПВ и ДНС на основе набора входных характеристик.

Для каждой точки данных (i) в выборке был рассчитан остаток (формула 3.4), путем сравнения предсказанных (PT_i) и измеренных (MT_i) значений Ф, ПВ и ДНС. Кроме того, для каждого элемента выборки было вычислено Махаланобисово расстояние (MD_i) с использованием формулы 3.5. После выбора соответствующего

порогового значения, значения в выборке, превышающие заданный порог Махаланобисова расстояния, были определены как выбросы. Обнаруженные выбросы были исключены из процесса моделирования Φ , ПВ и ДНС.

$$Res_i = MT_i - PT_i, \quad (3.4)$$

$$MD_i = \sqrt{Err_i \times (\text{cov}(Err))^{-1} \times Err_i^t}, \quad (3.5)$$

На кросс-плоте остатков и прогнозируемых значений Φ , представленном на Рисунке 3.3, можно увидеть выбросы, которые были обнаружены в прогнозе Φ с помощью метода расстояния Махаланобиса, а также представлена гистограмма распределения остатков. Результаты показывают, что после применения данного метода к обучающим данным было выявлено 42 значения, классифицированных как выбросы, и они были удалены из исследования с целью предотвращения их негативного влияния на анализ.

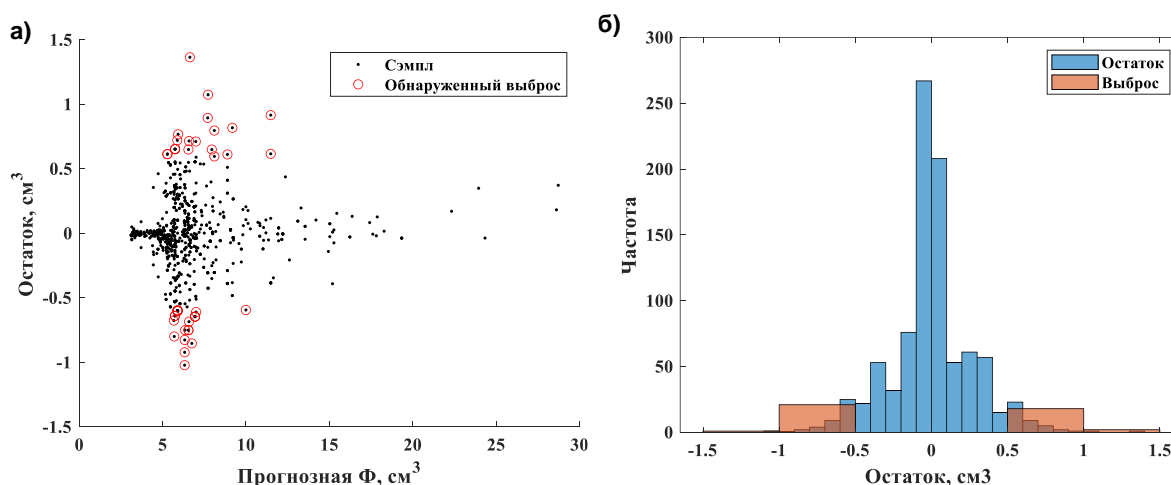


Рисунок 3.3 – Кросс-плот остатков и прогнозируемых значений Φ (а), а также гистограмма остатков (б). Выбросы, которые были выявлены и затем удалены из обучающего поднабора данных, обозначены красными кругами на кросс-плоте и широкими полосами на гистограмме.

Метод обнаружения выбросов был применен к обучающим данным для прогноза ПВ, как показано на Рисунке 3.4.

а)

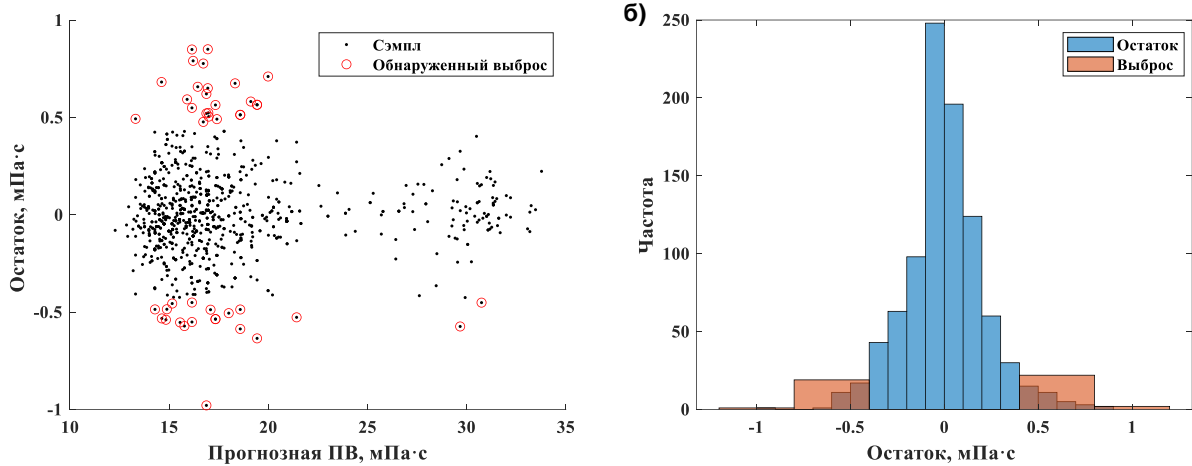


Рисунок 3.4 – Кросс–плот остатков и прогнозируемых значений ПВ (а), а также гистограмма остатков (б). Выбросы, которые были выявлены и последующее удалены из обучающего поднабора данных, обозначены красными кругами на кросс–плоте и широкими полосами на гистограмме.

На рисунке 3.4 можно увидеть расположение выявленных выбросов на кросс–плоте, который сопоставляет значения остатков с прогнозируемым ПВ, а также включает гистограмму распределения остатков. В результате применения этого метода было выявлено 44 значения определенных как выбросы, и затем они были удалены из анализа.

Прогнозирование параметра ДНС включало применение метода обнаружения выбросов на обучающих данных. Результаты этого метода представлены на рисунке 3.5, который включает кросс–плот остатков и прогнозируемых значений ДНС, а также гистограмму остатков. После применения метода было выявлено 50 значений, классифицированных как выбросы. Эти выбросы были удалены из процесса разработки модели прогнозирования ДНС, обеспечивая более точные результаты.

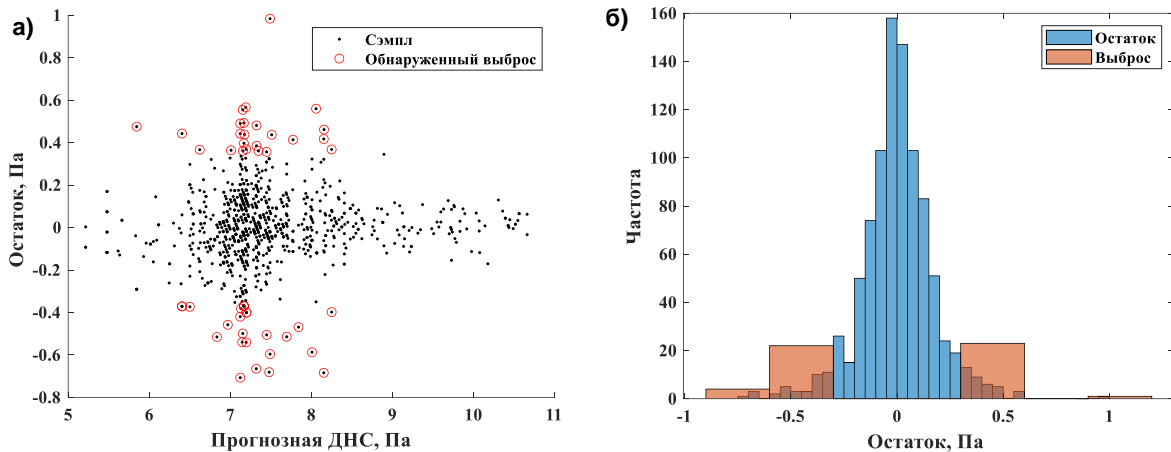


Рисунок 3.5 – (а) Выявленные выбросы на кросс–плоте остатков и прогнозируемых значений ДНС, и (б) гистограмма значений остатков. Выбросы, удаленные из обучающего поднабора данных, обозначены красными кругами на кросс–плоте и широкими полосами на гистограмме.

3.3. Определение оптимальной структуры моделей

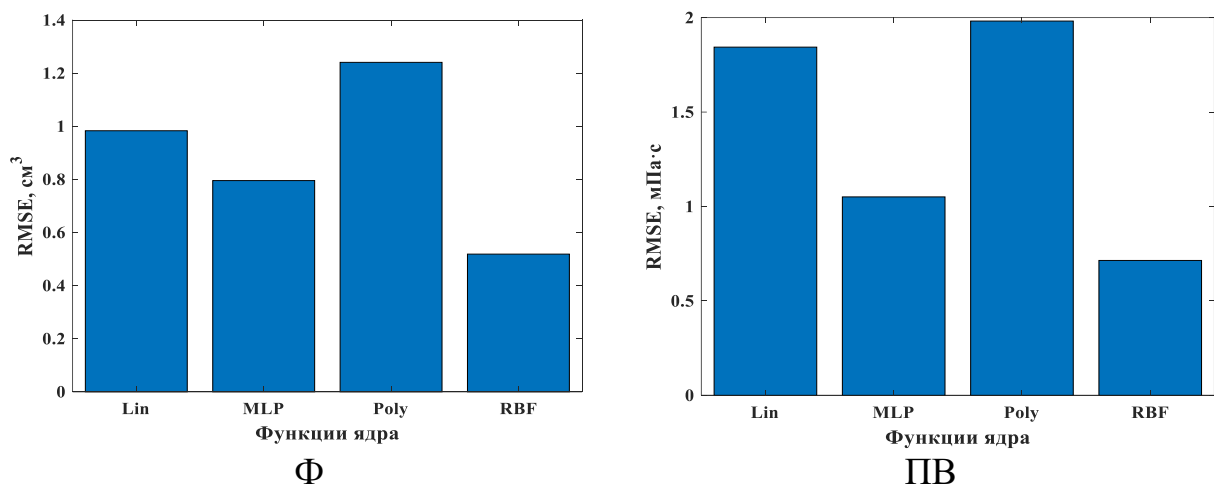
Для достижения высокой эффективности в MELM критически важно определить оптимальную структуру модели, в частности, выбрав подходящее количество скрытых слоев и число узлов на каждом слое. Если задать слишком мало узлов, модель может быть недообучена, в то время как задание чрезмерного их числа может привести к переобучению. Кроме того, важно выбрать правильную функцию активации для скрытых узлов. Среди общепринятых вариантов функций активации включаются сигмоида, тангенс нелинейная функция активации (ReLU).

В LSSVM критически важно определить оптимальное ядро функции и ее гиперпараметры для достижения высокой эффективности модели. Обычно используются такие функции ядра, как линейная, полиномиальная, радиальная базисная функции и многослойный перцептрон. Функция ядра отвечает за нелинейное преобразование входных данных в пространство более высокой размерности для LSSVM. Правильным выбором ядра можно улучшить способность обобщения и точность модели LSSVM. В следующих подразделах будет предоставлено подробное объяснение процедур, используемых для определения оптимальной структуры модели MELM и наиболее эффективного ядра для модели LSSVM.

3.3.1. Выбор ядра для LSSVM

Как упоминалось ранее, при разработке прогнозных моделей для параметров Φ , ПВ и ДНС с использованием LSSVM, функция ядра является ключевым параметром, который должен быть выбран. Для определения оптимальной функции ядра, в данном исследовании был использован подход метода проб и ошибок. Конкретно, модели LSSVM были разработаны и оценены с использованием четырех различных функций ядра – линейная (lin), полиномиальная (poly), многослойный перцептрон (MLP), радиальная базисная функция (RBF). Алгоритм сеточного поиска (Grid Search) был использован для определения подходящих гиперпараметров для каждой функции ядра.

Среднеквадратичные отклонения (RMSE) каждой полученной модели, выполненной на обучающих данных, показаны на рисунке 3.6. Как видно, функция ядра RBF дала наименьшее значение RMSE для всех трех целевых параметров. Исходя из этих результатов, функция ядра RBF была выбрана для построения моделей LSSVM для прогнозирования параметров Φ , ПВ и ДНС в данном исследовании. Оптимизационные алгоритмы для LSSVM должны подобрать лучшие значения для двух гиперпараметров: сигмы и гаммы, основанные на выбранной функции ядра.






Рисунок 3.6 – Сравнение RMSE моделей LSSVM с разными функциями ядра для прогнозирования Φ , ПВ и ДНС на обучающих данных.

3.3.2. Выбор оптимальной архитектуры для MELM

Алгоритм COA был использован для определения оптимальной архитектуры MELM в связи с обширными оценками, которые требуются, и трудоемкостью ручных методов. Эти оценки включают в себя различные критерии, такие как точность предсказания, скорость обучения, время выполнения и другие метрики, позволяющие оценить эффективность модели. Ручные методы оценки требуют значительных усилий и времени, поскольку исследователь должен проводить эксперименты с различными параметрами и архитектурами модели, а затем анализировать и интерпретировать полученные результаты. Вместо этого, применение алгоритма COA позволяет автоматизировать процесс выбора оптимальной архитектуры MELM, исследуя различные варианты архитектур и параметров модели и оценивая их производительность, что существенно сокращает трудозатраты и время, необходимые для проведения оценок. Главной задачей было определить оптимальное количество скрытых слоев и узлов в каждом слое. Это требовало определения подходящих диапазонов для переменных решения, таких как количество скрытых слоев и узлов в каждом слое. Для данного исследования были выбраны определенные диапазоны значений для скрытых слоев и узлов, которые показали наилучшие результаты прогнозирования Φ , ПВ и ДНС. Модели MELM с архитектурой, варьирующейся от 2 до 10 скрытых слоев, и одинаковым

количеством узлов в каждом слое от 1 до 12, были использованы для прогнозирования Φ , ПВ и ДНС на обучающих данных. Из-за стохастической природы MELM, обусловленной случайной инициализацией весов и смещений, каждая конфигурация модели запускалась 1000 раз. Конфигурация, обеспечивающая наименьшую ошибку (RMSE), считалась наиболее оптимальной для данной архитектуры. Уточнение диапазонов переменных решения в алгоритме оптимизации может ускорить поиск наилучшего решения. Рисунок 3.7 показывает контурный график, иллюстрирующий изменения значений RMSE при прогнозировании параметров Φ , ПВ и ДНС моделями MELM я различными переменными решений.

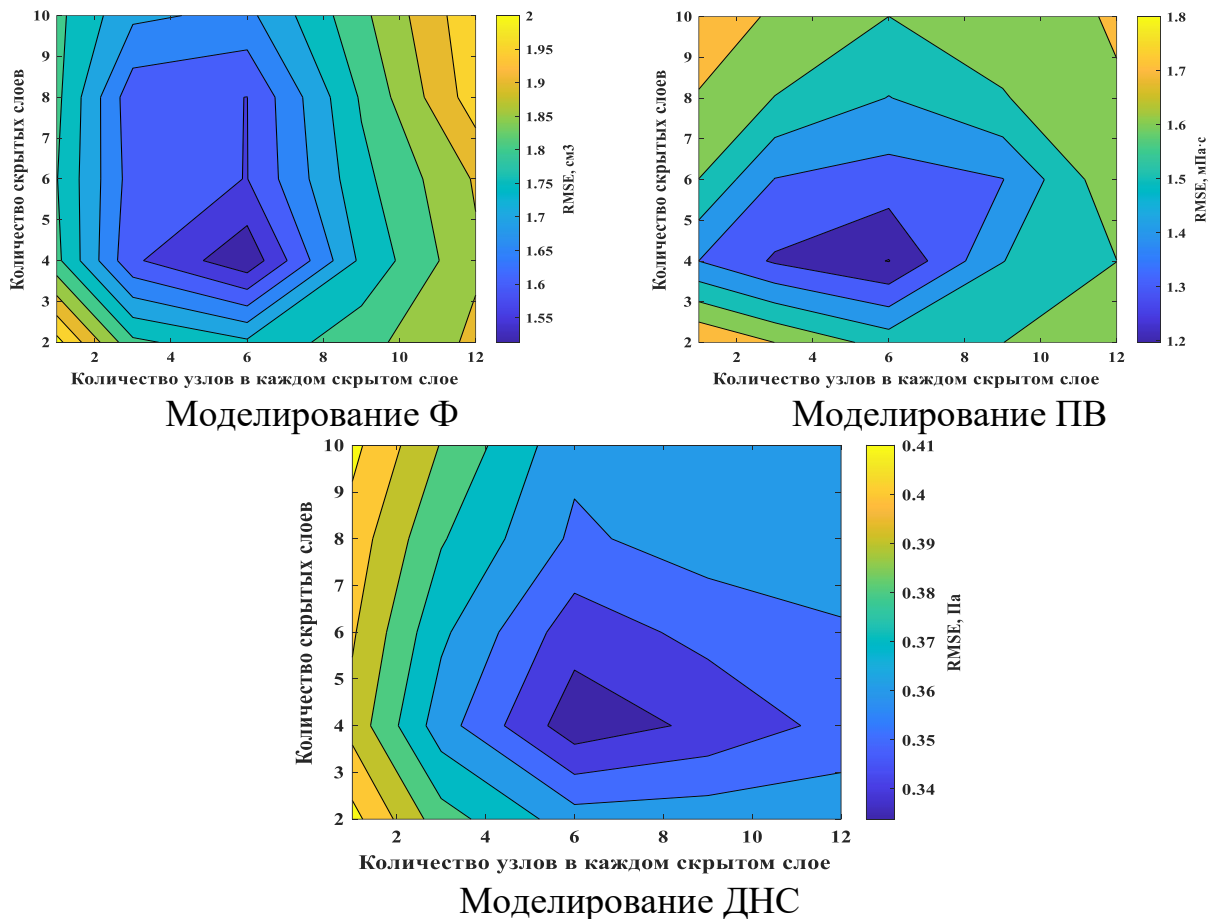


Рисунок 3.7 – Контурный график, иллюстрирующий распределение значений RMSE прогнозирования Φ , ПВ и ДНС моделью MELM на основе обучающих данных в зависимости от используемого количества скрытых слоев и узлов в каждом слое.

Рисунок 3.7 подчеркивает влияние изменения количества скрытых слоев и узлов на слой на RMSE во время обучения. Примечательно, что область с наименьшей ошибкой прогноза для этих параметров находится между 3 и 7 скрытыми слоями и 2 и 10 узлами в каждом слое. Это предполагает, что конфигурации в этом диапазоне могут предложить более точные прогнозы для рассматриваемых параметров.

После установления диапазона для каждой переменной решения, можно применить СОА чтобы определить оптимальную архитектуру модели MELM. Алгоритм был запущен на 50 итераций с начальной популяцией из 50 кукушек, ограниченной максимумом в 60 кукушек. Кроме того, диапазон числа яиц был установлен между 5 и 10. Учитывая случайную инициализацию весов и смещений в MELM, точность прогнозирования может варьироваться, даже для одной и той же структуры. Это несоответствие может влиять на достоверность результатов СОА. Чтобы компенсировать случайность инициализации весов и смещений, каждая уникальная конфигурация MELM, оцениваемая во время применения СОА, выполняется 1000 раз. На основании проведенных запусков моделей с различными структурами, наименьшее значение RMSE будет представлять ошибку для конкретной структуры, указывая на лучшую конфигурацию MELM с наиболее точными прогнозами для параметров Ф, ПВ и ДНС. Уменьшив чувствительность RMSE к случайным факторам, СОА может более эффективно определить лучшую архитектуру MELM, используя последовательные показатели точности. На рисунке 3.8 представлена картина сходимости СОА за 50 итераций при определении оптимальной структуры MELM с использованием обучающих данных. График показывает снижение и последующую стабилизацию значений RMSE с каждой последующей итерацией прогнозирования параметров Ф, ПВ и ДНС.




Рисунок 3.8 –Изменение значений RMSE прогнозирования Ф, ПВ и ДНС при увеличении числа итераций COA.

Как показано на рисунке 3.8, в начале значения RMSE для ФВ, ПВ и ДНС повышены, что указывает на неоптимальную конфигурацию модели MELM. Однако, начиная с 15–той итерации COA наблюдается заметное снижение значений RMSE для всех трех выходных параметров, что указывает на повышение эффективности алгоритма в настройке структуры MELM. К 30–ой итерации значения RMSE стабилизируются для всех трех переменных, что свидетельствует о достижении оптимального решения с минимальной ошибкой. Эффективность COA подчеркивает его способность эффективно перемещаться по пространству конструкций и определить оптимальную архитектуру MELM всего за 30 итераций. Последующий анализ результатов COA выявил, что оптимальной структурой MELM для прогнозирования всех трех параметров является композиция из четырех скрытых слоев, содержащих 4, 3, 2 и 2 узла в каждом слое соответственно. Эта

конфигурация будет использоваться для моделирования Ф, ПВ и ДНС в MELM. Для определения наиболее подходящей функции активации для MELM были оценены функции «sigmoid» и «radbas». Различные комбинации этих функций активации были протестированы на четырех скрытых слоях алгоритма MELM, подробно описанных в Таблице 3.1. Оптимальная структура, показанная выше, была использована для применения каждой комбинации на обучающих данных. Учитывая внутреннюю случайность инициализации весов и смещений, алгоритм был запущен 1000 раз для обеспечения последовательности результатов.

Таблица 3.1. – Различные комбинации функций активации, оцененные на скрытых слоях модели MELM.

Код комбинации	Функция активации скрытого слоя			
	1 st	2 nd	3 rd	4 th
1	radbas	radbas	radbas	radbas
2	sigmoid	sigmoid	sigmoid	sigmoid
3	radbas	radbas	radbas	sigmoid
4	radbas	radbas	sigmoid	radbas
5	radbas	sigmoid	radbas	radbas
6	sigmoid	radbas	radbas	radbas
7	sigmoid	sigmoid	radbas	radbas
8	sigmoid	radbas	sigmoid	radbas
9	sigmoid	radbas	radbas	sigmoid
10	radbas	sigmoid	radbas	sigmoid
11	radbas	radbas	sigmoid	sigmoid
12	radbas	sigmoid	sigmoid	radbas
13	sigmoid	sigmoid	sigmoid	radbas
14	sigmoid	sigmoid	radbas	sigmoid
15	sigmoid	radbas	sigmoid	sigmoid
16	radbas	sigmoid	sigmoid	sigmoid

На рисунке 3.9 показаны значения RMSE при прогнозировании ФВ, ПВ и ДНС с использованием различных комбинаций функции активации. Видно, что альтернативная комбинация номер 1 дала наименьшую ошибку прогнозирования

всех трех параметров, что указывает на исключительное использование функции активации «radbas» на всех скрытых слоях. Следовательно, данная функция будет использоваться для последующего моделирования.




Рисунок 3.9 – Сравнение RMSE для моделирования MELM на основе обучающих данных с использованием комбинаций функций активации, описанных в Таблице 3.1.

3.4. Настройка параметров алгоритмов оптимизации

Для оптимизации значений гиперпараметров прогностических моделей в комбинированной структуре оптимизации и алгоритмов машинного обучения необходимо калибровать управляющие параметры данных методов оптимизации на основе особенностей задачи. Перед тем как приступить к реализации этого подхода, алгоритмы должны быть объединены. В этом процессе используется целевая функция оптимизационного алгоритма, которая в данном исследовании направлена на минимизацию ошибки RMSE. Для расчета значений RMSE необходимо использовать как фактические данные, так и прогнозные значения, которые получают с помощью прогностических моделей. RMSE (корень из среднеквадратичной ошибки) является мерой разницы между фактическими значениями и прогнозными значениями и позволяет оценить точность прогнозирования. Оптимизационный алгоритм предоставляет гиперпараметры прогностической модели, стимулируя её генерировать прогнозы с целью снижения

RMSE по параметрам Φ , ПВ и ДНС. Это сгенерированное значение ошибки служит в качестве погрешности, связанной со значениями гиперпараметров, переданными прогностической модели. Основной целью оптимизационного алгоритма является постепенное уменьшение этой погрешности путем предложения улучшенных значений гиперпараметров. Определение количества переменных решения является ключевым фактором в алгоритмах оптимизации. Для комбинированного подхода GA или COA для оптимизации LSSVM, учитывая, что ядро LSSVM – RBF, обучение модели оптимизирует два гиперпараметра: сигма (σ^2) и гамма (γ) отвечающие за оптимизацию модели и настройку ядра LSSVM, которое в данном случае является RBF. Следовательно, количество переменных решения для алгоритма оптимизации (GA или COA) составляет два. В контексте оптимизационного алгоритма, совмещенного с MELM, количество переменных решения зависит от выбранной структуры и количества входных параметров. В данном исследовании для прогнозирования трех параметров: Φ , ПВ и ДНС, была использована определенная структура гибридных моделей и три постоянных входных параметра ($T\Phi$, ρ_{br} , и UB). Таким образом, количество переменных решения соответствует этим трем параметрам при оптимизации совместно с MELM. Выявленная оптимальная конфигурация MELM в данном исследовании содержит четыре узла в первом слое и три входных параметра ($T\Phi$, ρ_{br} , и UB), что требует 12 весов в этом слое. Второй слой содержит три узла, а входными данными для него служат выходы из первого слоя, что требует еще 12 весов. Предпоследний слой содержит два узла и три входных параметра, что требует 6 весов. Последний слой состоит из двух узлов и двух входных параметров, что требует 4 веса. Итак, оптимальная структура требует 34 весов. Учитывая также смещение для каждого слоя, общее количество переменных решения возрастает до 38. Размер популяции, будучи важным параметром в алгоритмах оптимизации, должен быть правильно настроен. Меньший размер популяции увеличивает скорость вычислений на каждой итерации, но может потребовать больше итераций для сходимости к оптимальному решению. В то же время, больший размер популяции замедляет скорость вычислений на каждой итерации, но может потребовать меньшее число

итераций для достижения решения. Для определения подходящих значений размера популяции, был принят подход проб и ошибок. В данной работе размер популяции в гибридных алгоритмах варьировался в диапазоне от 100 до 200. На рисунке 3.10 представлено сравнение значений RMSE при размерах популяции от 100 до 200 для GA и COA в сочетании с MELM для прогнозирования Φ . Из рисунка видно, что ошибка уменьшается с увеличением размера популяции. Однако снижение ошибки достигает плато при размере популяции свыше 140 для COA и 170 для GA, тогда как время вычислений экспоненциально возрастает.




Рисунок 3.10 – Оценка влияния изменения размера популяции на значения RMSE в алгоритмах GA и COA, при их совместном использовании с MELM для прогнозирования Φ .

Следовательно, для прогнозирования Φ оптимальный размер популяции составляет 170 для GA и 140 для COA. Количество итераций для алгоритмов оптимизации было зафиксировано на уровне 50 для этого анализа. Это исследование было проведено и для двух других параметров (ПВ и ДНС). Полученные результаты показали, что в гибридных алгоритмах оптимизации с MELM оптимальный размер популяции для GA и COA остается равным 170 и 140 соответственно.

Процедура подбора оптимального размера популяции была выполнена и для оптимизации алгоритмов, работающих с моделью LSSVM. На рисунке 3.11

показано, как изменение размера популяции в диапазоне от 80 до 150 влияет на значения RMSE для оптимизационных алгоритмов, работающих в совместной связке с моделью LSSVM, применяемых специально для разработки модели прогнозирования Φ с использованием обучающих данных.




Рисунок 3.11 – Оценка влияния изменения размера популяции на значения RMSE в алгоритмах GA и COA, при их совместном использовании с MELM для прогнозирования Φ .

Рисунок 3.11 показывает, что значения ошибки достигают плато для алгоритма GA, когда размер популяции достигает 120, и аналогично для алгоритма COA при размере популяции 100. При этом время обработки значительно возрастает при превышении указанных размеров популяции. Это исследование также было проведено для определения оптимального размера популяции в гибридном подходе, объединяющем оптимизационные алгоритмы с моделью LSSVM для прогнозирования ПВ и ДНС. Полученные результаты соответствуют тем, что были получены для прогнозирования Φ . Таким образом, для разработки гибридных прогностических моделей для ПВ и ДНС, где LSSVM объединяется с GA и COA, был выбран оптимальный размер популяции в 120 для алгоритма GA и 100 для алгоритма COA.

Определение подходящих значений для других параметров настройки в оптимизационных алгоритмах было достигнуто через анализ чувствительности,

результаты которого представлены в Таблице 3.2. Важно отметить, что алгоритм GA демонстрирует заметно более высокую скорость обработки по сравнению с алгоритмом COA. Кроме того, для всех исследуемых оптимизационных алгоритмов количество итераций было постоянно установлено на уровне 200.

В данном исследовании автономная модель LSSVM использует локальный алгоритм оптимизации для точной настройки своих гиперпараметров. Были изучены три следующих алгоритма: Grid Search (GS), градиентный спуск (GD) и метод сопряжённых градиентов (CG). С целью повышения точности прогностической модели LSSVM был проведён анализ чувствительности управляющих параметров указанных локальных алгоритмов оптимизации. Основная цель этого анализа заключается в выявлении оптимальных значений для указанных параметров.

Таблица 3.2 – Оптимальные значения контрольных параметров, установленные для оптимизаторов GA и COA, применяемых к разработанным гибридным моделям МО для прогнозирования целевых параметров бурового раствора.

Оптимизаторы	Контрольные параметры	Предикторы	
		MELM	LSSVM
GA	Начальная численность популяции	170	120
	Метод отбора	Roulette	Roulette wheel
	Давление отбора (roulette wheel)	2	2
	Скращивание	Uniform	Uniform
	Мутация	Uniform	Uniform
	Скорость мутации	0,05	0,05
COA	Начальная численность популяции	140	100
	Максимальное количество кукушек	150	110
	Минимальное количество яиц для каждой кукушки	5	5
	Максимальное количество яиц на каждую кукушку	10	10
	Количество кластеров	1	1

В Таблице 3.3 представлены результаты данного анализа чувствительности, включая конкретные значения управляющих параметров для каждого рассматриваемого локального оптимизатора.

Таблица 3.3. Значения управляющих параметров для локальных алгоритмов оптимизации, использованных в автономной модели LSSVM.

Оптимизатор	Управляющий параметр	Значение
GS	Максимальное Число итераций	200
	Допустимая ошибка функции (function tolerance)	0,0001
	Допустимая ошибка X (X tolerance)	0,0001
	Начальное значение для генератора случайных чисел (grain or seed)	7
CG	Число итераций	100
	Допустимая ошибка функции (function tolerance)	0,0001
GD	Число итераций	100
	Шаг обучения (learning rate)	0,009

3.5. Оптимизация гиперпараметров алгоритмов прогнозирования

В процессе моделирования нашей целью является настройка гиперпараметров алгоритмов прогнозирования, а именно MELM и LSSVM, в соответствии с конкретными условиями задачи. В данном разделе будет раскрыт подход к определению оптимальных значений гиперпараметров для каждого алгоритма прогнозирования с использованием техник оптимизации.

3.5.1. Оптимизация гиперпараметров модели LSSVM

Для определения оптимальных гиперпараметров для модели LSSVM обычно используются локальные алгоритмы оптимизации: поиск по сетке (GS), градиентный спуск (GD) и метод сопряжённых градиентов (CG). Методы CG и GD оптимизируются путем решения квадратичной задачи оптимизации и минимизации целевой функции, как правило, оцениваемой по значению ошибки MSE. Однако эти методы могут «застрять» в локальных минимумах. Для преодоления этого ограничения в данном исследовании также используются глобальные алгоритмы оптимизации, а именно генетический алгоритм (GA) и алгоритм оптимизации COA. Таким образом, в этом исследовании оцениваются пять методов оптимизации: три локальных (CG, GD и GS) и два глобальных (GA и

COA) метода. Все направленные на определение наилучших настроек гиперпараметров для модели LSSVM.

Важным фактором в алгоритмах оптимизации является определение количества переменных решения. Для комбинированного подхода LSSVM с использованием генетического алгоритма (GA) и/или алгоритма оптимизации COA, учитывая, что ядро LSSVM является радиальной базисной функцией (RBF), при обучении модели оптимизируются два гиперпараметра: сигма (σ^2) и гамма (γ). В результате количество переменных решения для алгоритма оптимизации (GA или COA) составляет два.

Для определения количества переменных решения в алгоритмах оптимизации необходимо установить диапазон изменчивости для каждой переменной. Например, диапазон для значения σ^2 был установлен от 0,001 до 100, в то время как значение γ изменялось в диапазоне от 0,001 до 5000. На начальных этапах алгоритмы оптимизации генерируют значения в пределах установленных диапазонов. Затем эти значения служат входными параметрами для алгоритма LSSVM, позволяя ему построить прогностическую модель. Используя предоставленные гиперпараметры, модель LSSVM прогнозирует три целевых параметра. Разница между этими прогнозами и фактическими значениями целевых параметров рассчитывается как среднеквадратичное отклонение, представляющая собой метрику стоимости, связанную с данными гиперпараметрами. С каждой итерацией алгоритмы оптимизации изменяют гиперпараметры в соответствии со своими внутренними процедурами оптимизации. Этот итеративный механизм продолжается заранее установленное количество итераций, идентифицируя оптимальные значения гиперпараметров.

В Таблице 3.4 представлены значения гиперпараметров, полученные с использованием различных алгоритмов оптимизации при обучении LSSVM для прогнозирования ФВ, ПВ и ДНС.

Таблица 3.4. Значения гиперпараметров, полученные с использованием различных алгоритмов оптимизации при обучении LSSVM для прогнозирования ФВ, ПВ и ДНС.

Целевой параметр	Оптимизатор	Значения гиперпараметров	
		σ^2	γ
Ф	GD	1,2511	219,3868
	CG	1,3084	351,3644
	GS	1,3933	581,8676
	GA	1,4291	730,1398
	COA	1,4382	739,8546
ПВ	GD	4,8419	215,1965
	CG	4,8064	210,6206
	GS	4,6714	193,5121
	GA	4,7938	287,8345
	COA	1,6566	2688,1271
ДНС	GD	0,6489	102,7981
	CG	0,6778	103,4177
	GS	0,5679	112,5771
	GA	0,5529	117,9342
	COA	0,5346	121,0984

RMSE ошибки прогнозирования целевых параметров Ф, ПВ и ДНС, полученных в результате запуска моделей LSSVM, оснащенных пятью различными методами локальной (CG, GD, и GS) и глобальной (COA и GA) оптимизации, представлены на рисунке 3.12.

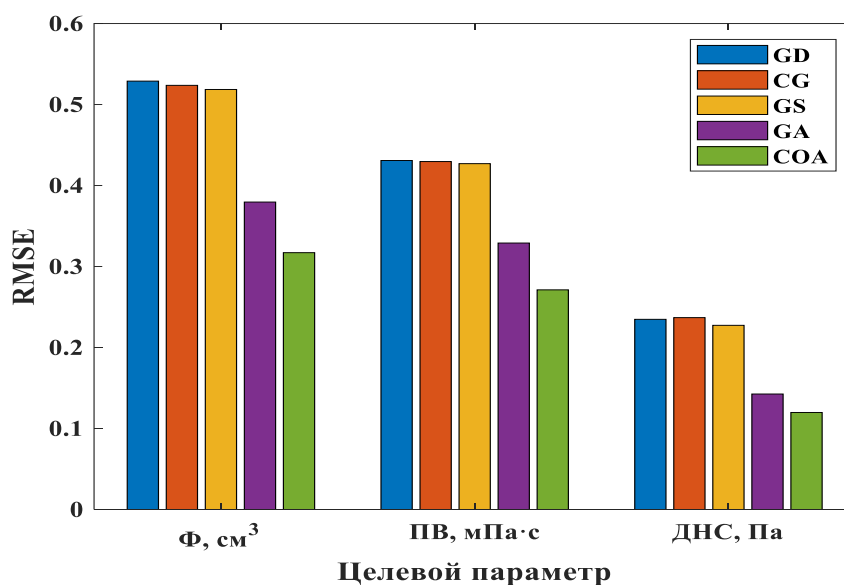


Рисунок 3.12 – Анализ RMSE моделей LSSVM, использующих разнообразные алгоритмы оптимизации для прогнозирования целевых параметров с использованием подмножества данных обучения.

При исследовании Рисунка 3.12 становится очевидным, что среди изученных локальных методов оптимизации (GD, CG и GS), модель LSSVM с алгоритмом GS демонстрирует наименьшее значение среднеквадратичного отклонения (RMSE) при прогнозировании целевых параметров. Впредь модель LSSVM, сочетающаяся с оптимизатором GS, будет просто называться моделью LSSVM. При сравнении значений RMSE, полученных с использованием LSSVM с локальными методами оптимизации, с значениями, полученными с использованием глобальных методов оптимизации (GA и COA), глобальные методы, GA и COA, продемонстрировали более высокую производительность в определении оптимальных гиперпараметров. Это подтверждается более низкими значениями RMSE для прогнозов, полученных с помощью моделей LSSVM, оптимизированных с использованием глобальных методов оптимизации.

В следующей главе будет проведено более подробное сравнение между моделью LSSVM, интегрированной с методом оптимизации GS (самым эффективным среди локальных методов), и моделями LSSVM, объединенными с глобальными методами оптимизации – GA и COA.

На Рисунке 3.13 проиллюстрировано снижение значения RMSE при использовании двух глобальных алгоритмов оптимизации – GA и COA. Из графического представления на данном рисунке следует, что убывающая тенденция ошибки в обоих алгоритмах стабилизируется после проведения 80–й итерации для Φ и ПВ. Кроме того, анализ рисунка 3.13 позволяет сделать вывод о том, что алгоритм COA достигает оптимального решения более быстро и предоставляет более точное решение по сравнению с методом GA. При прогнозировании ДНС влияют различные факторы, включая состав раствора, температуру, давление и другие условия бурения. Сложная и многогранная природа ДНС затрудняет точное отражение всех основных взаимосвязей, что может влиять на эффективность прогнозирования с использованием моделей.




Рисунок 3.13 – Изменение значения RMSE в зависимости от итераций для алгоритмов оптимизации при прогнозировании Φ , ПВ и ДНС с использованием гибридных моделей LSSVM.

На Рисунке 3.14 произведено сравнение времени обработки между гибридными алгоритмами и независимой моделью LSSVM, которая использует метод GS в качестве своего оптимизатора, для прогнозирования Φ .

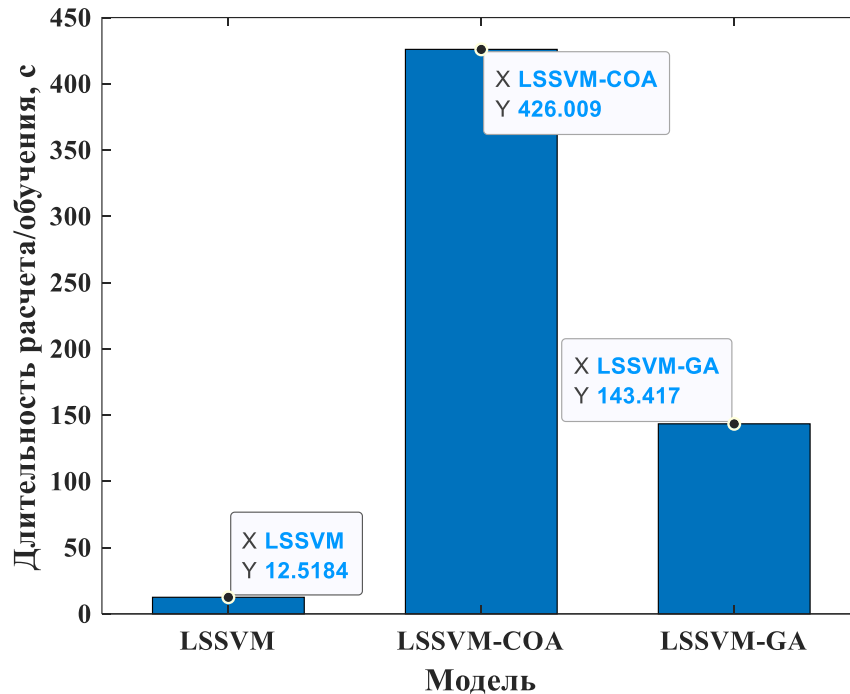


Рисунок 3.14 – Сравнение времени обработки при обучении автономной модели LSSVM по сравнению с её гибридными аналогами, LSSVM–GA и LSSVM–COA, разработанными для прогнозирования Φ .

Очевидно, что время обработки независимой модели LSSVM оказывается быстрее, чем у её гибридных аналогов. Важно отметить, что хотя модель LSSVM–GA, опережает другой гибридный вариант LSSVM–COA, вычислительная скорость, затраченная на обучение автономной модели LSSVM (LSSVM–GS), по-прежнему значительно ниже. Аналогичные результаты были получены при разработке прогностических моделей для ПВ и ДНС. Важно подчеркнуть, что хотя время обработки имеет существенное значение в процессе разработки гибридных моделей, оно не влияет на производительность модели на новых, не тестовых ранее данных.

3.5.2. Оптимизация гиперпараметров модели MELM

Для алгоритмов оптимизации, совмещенных с MELM, количество переменных принятия решений зависит от используемой структуры и количества входных характеристик. В данном исследовании выбранная структура MELM и три постоянные входные характеристики используются для оценки трех параметров: Φ , ПВ и ДНС. Оптимальная структура для MELM в данном исследовании включает четыре узла в первом скрытом слое и три входные характеристики, что требует 12 весов для первого скрытого слоя. Второй скрытый слой имеет три узла, и вывод первого скрытого слоя служит входом, требуя 12 весов. Третий скрытый слой имеет два узла и три входные характеристики, что требует 6 весов. Наконец, четвертый скрытый слой имеет два узла и две входные характеристики, что требует 4 веса. В общей сложности, оптимальная структура требует 34 веса. Кроме того, так как для каждого скрытого слоя используется смещение (bias), общее количество переменных принятия решений составит 38.

Во время начальной итерации алгоритмов глобальной оптимизации 38 решающим параметрам присваиваются случайные значения. Затем они интегрируются в MELM в качестве весов и смещений, обеспечивая построение предиктивной модели. Эта модель затем вычисляет зависимые параметры Φ , ПВ и ДНС. Возможные ошибки прогноза параметров количественно оцениваются и используются как индикаторы настроек гиперпараметров в алгоритмах оптимизации. В последующих итерациях эти алгоритмы используют свои внутренние механизмы для уточнения и улучшения значений гиперпараметров. Этот итеративный процесс продолжается заданное число итераций. В результате определяются наиболее подходящие значения гиперпараметров.

На рисунке 3.15 представлено поведение значений RMSE с увеличением числа итераций для алгоритмов оптимизации при создании гибридных моделей MELM для прогнозирования параметров Φ , ПВ и ДНС.




Рисунок 3.15 – Изменение значения RMSE в зависимости от количества итераций для алгоритмов оптимизации при прогнозировании Φ , ПВ и ДНС с использованием гибридных моделей MELM.

Рисунок 3.15 указывает на быструю сходимость к оптимальным решениям обоими глобальными оптимизаторами в первых 20 итерациях. Однако после 20-й итерации скорость сходимости значительно снижается, и после 80-й итерации достигает плато. Кроме того, анализ рисунка позволяет сделать вывод, что алгоритм COA достигает оптимального решения быстрее и предоставляет более точное решение по сравнению с методом GA.

На рисунке 3.16 сравниваются время затраты трех моделей: автономной MELM и ее гибридных вариантов MELM-GA и MELM-COA во время обучения модели прогнозирования параметра Φ .

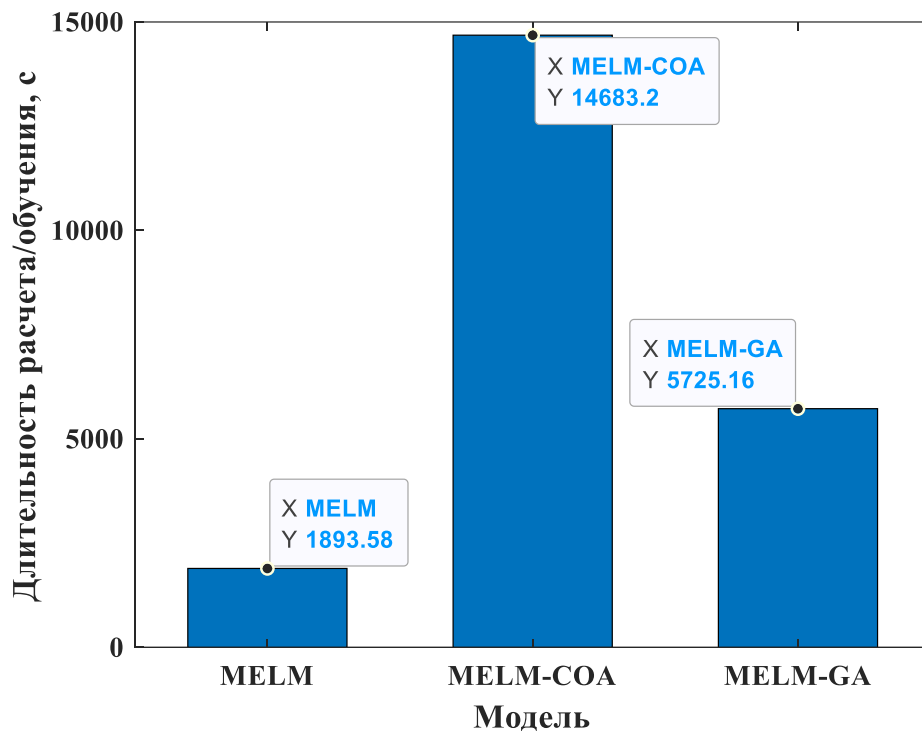


Рисунок 3.16 – Сравнение времени обработки при обучении автономной модели MELM по сравнению с её гибридными аналогами, MELM–GA и MELM–COA, разработанными для прогнозирования Ф.

Из рисунка видно, что автономная модель MELM работает существенно быстрее, чем ее гибридные аналоги. Скорость расчетов автономной модели MELM, измеренная на протяжении 1000 запусков, составляет в среднем 1,8543 секунды на запуск. Эта эффективность модели MELM обусловлена случайным распределением весов и смещений. Тем не менее, один случайный запуск не всегда гарантирует максимальную точность. Поэтому рекомендуется проводить несколько запусков модели MELM для повышения вероятности получения более точной предиктивной модели, даже если она не всегда будет оптимальной.

Среди гибридных версий MELM–GA демонстрирует более быструю скорость обучения, чем MELM–COA. Кроме того, были замечены сравнимые времена обработки при обучении гибридных предиктивных моделей для параметров ПВ и ДНС. Важно подчеркнуть, что продолжительность обучения не должна быть единственным фактором при выборе модели. В предиктивном моделировании приоритет отдается точности и обобщаемости модели перед временем обучения.

После успешного обучения прочной предиктивной модели она способна быстро и точно анализировать новые, невиданные наборы данных.

В общем и целом, в данной главе были выполнены следующие шаги: проведен контроль качества данных, удалены выбросы, определены оптимальные структуры и конфигурации моделей, а также настроены алгоритмы оптимизации. Следующим шагом будет использование этих моделей в практических задачах, таких как прогнозирование параметров Ф ПВ, и ДНС. Это предисловие для следующей главы, где будут рассмотрены конкретные сценарии и применение этих моделей в реальных задачах бурения.

ГЛАВА 4. Результаты прогнозирования гибридных моделей машинного обучения

Данная глава посвящена применению гибридных алгоритмов к обучающим данным и разработке прогностических моделей для реологических свойств бурового раствора. Далее разработанные и обученные модели будут применены к тестовым данным. Результаты каждого из этих шагов будут оцениваться с использованием различных критериев оценки погрешности.

4.1. Прогнозирование водоотдачи

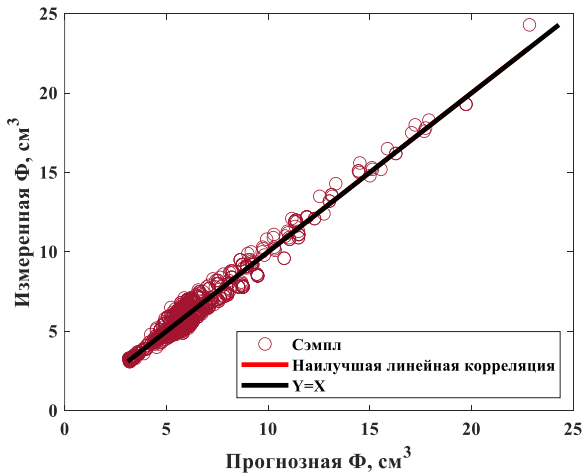
Ниже сравниваются погрешности прогнозирования водоотдачи бурового раствора, полученные с использованием автономных моделей машинного обучения (МО), MELM и LSSVM, и их гибридных версий с оптимизаторами, MELM-GA/COA и LSSVM-GA/COA, на основе обучающего набора данных (таблице 4.1).

Таблица 4.1 – Значения погрешностей прогнозирования водоотдачи, достигаемые автономными и гибридными моделями МО для обучающего подмножества.

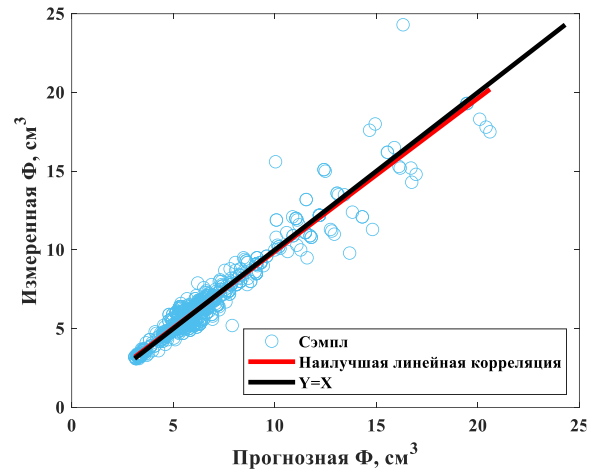
Тип модели МО	Модель	SD (см ³)	AAPD (%)	APD (%)	RMSE (см ³)	R ²
Автономные модели	LSSVM	0,5189	6,9398	-0,5490	0,5186	0,9565
	MELM	0,6616	5,1784	-0,3570	0,6612	0,9301
Гибридные модели	LSSVM-GA	0,3799	4,8145	-0,3474	0,3796	0,9767
	MELM-GA	0,3264	3,6920	-0,1056	0,3266	0,9828
	LSSVM-COA	0,3173	3,8191	-0,3554	0,3171	0,9842
	MELM-COA	0,2279	2,5799	-0,1532	0,2278	0,9916

В целом, гибридные модели МО прогнозируют значения водоотдачи с меньшей ошибкой, чем автономные модели LSSVM и MELM. Модель MELM-COA показала наилучший результат в точности прогнозирования водоотдачи. Ошибки прогнозирования составили AAPD 2,5799 и RMSE 0,2278, а коэффициент детерминации (R²) 0,9916 (Таблица 4.1) для обучающего подмножества. На рисунке 4.1 показаны прогнозные (на оси абсцисс) и измеренные (на оси ординат)


значения водоотдачи для обучающего подмножества данных для каждой из двух автономных моделей МО и четырех гибридных моделей МО.




а) Модель LSSVM



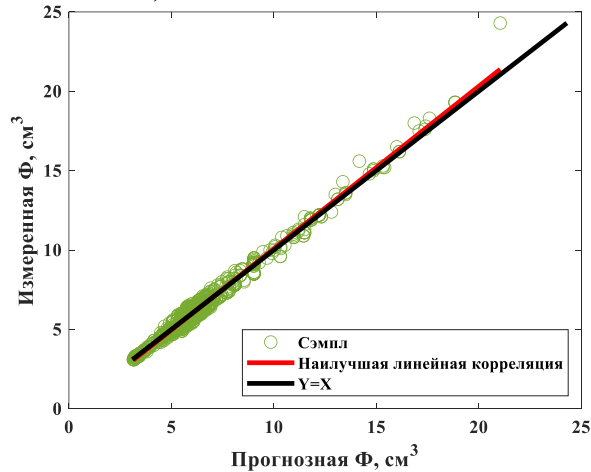
б) Модель MELM




в) Модель LSSVM-GA



г) Модель MELM-GA



д) Модель LSSVM-COA



с) Модель MELM-COA

Рисунок 4.1– Измеренные и прогнозные значения водоотдачи (Φ),

сгенерированные для обучающего подмножества двумя оцениваемыми автономными моделями МО и четырьмя оцениваемыми гибридными моделями МО.

Из Рисунка 4.1 видно, что прогнозные значения водоотдачи, полученные с использованием модели MELM имеют большую дисперсию по сравнению с результатами, полученными другими моделями. Это можно связать с случайным распределением весов и смещений в слоях, несмотря на 1000 проведенных итераций и выбор наилучшей модели из этих запусков. Однако, даже с этим разбросом, наилучшая подгонка регрессионной линии для MELM близка к линии $Y = X$, что указывает на "идеальное" воспроизведение значений моделью в среднем. Автономная модель LSSVM, хотя и показывает некоторый разброс относительно прямой $Y = X$, она превосходит стандартную модель MELM благодаря интеграции в первую модель оптимизатора GS (см. главу 3). В противоположность результатам на основе тестовых наборов данных, гибридные модели демонстрируют превосходную производительность по сравнению с автономными моделями, характеризующуюся значительно сниженным разбросом точек относительно линии $X = Y$.

В таблице 4.2 приведены погрешности прогнозирования значений водоотдачи при применении обученных автономных и гибридных моделей МО к тестовому набору данных.

Таблица 4.2 – Величины погрешностей прогнозирования значений водоотдачи, полученные автономными и гибридными моделями МО на основе тестовых наборов данных.

Тип модели МО	Модель	SD (см ³)	AAPD (%)	APD (%)	RMSE (см ³)	R ²
Автономные модели	LSSVM	0,6971	7,5141	1,3503	0,7124	0,9644
	MELM	1,0418	5,2309	1,4803	1,0604	0,9278
Гибридные модели	LSSVM-GA	0,5848	4,5799	0,5518	0,5881	0,9745
	MELM-GA	0,5414	2,0969	0,4886	0,5471	0,9805
	LSSVM-COA	0,5027	3,0016	0,5845	0,5107	0,9860
	MELM-COA	0,4366	2,9468	0,5400	0,4395	0,9858

Все шесть оцениваемых прогностических моделей воспроизводят значения водоотдачи с величинами R² выше 0,94 и RMSE ниже 1,07 см³. Эти результаты

подтверждают, что все шесть обученных моделей обеспечивают достоверность прогнозирования значений водоотдачи на тестовом наборе данных. Полученные оценки (таблица 4.2) показали, что гибридные модели значительно превзошли автономные модели. Это превосходство проявляется в заметно сниженных значениях RMSE и повышенных значениях R^2 , которые гибридные модели достигли по сравнению с их автономными аналогами (таблица 4.2).

На рисунке 4.2 сравниваются значения RMSE и R^2 (взяты из таблицы 4.2), связанные с прогнозными значениями водоотдачи, полученными каждой из шести обученных моделей для тестового подмножества данных. Эффективность прогнозирования водоотдачи обученными гибридными моделями МО для тестового подмножества данных может быть ранжирована в порядке возрастания RMSE: MELM-COA > LSSVM-COA > MELM-GA > LSSVM-GA, и в порядке возрастания R^2 : MELM-COA > LSSVM-COA > MELM-GA > LSSVM-GA.

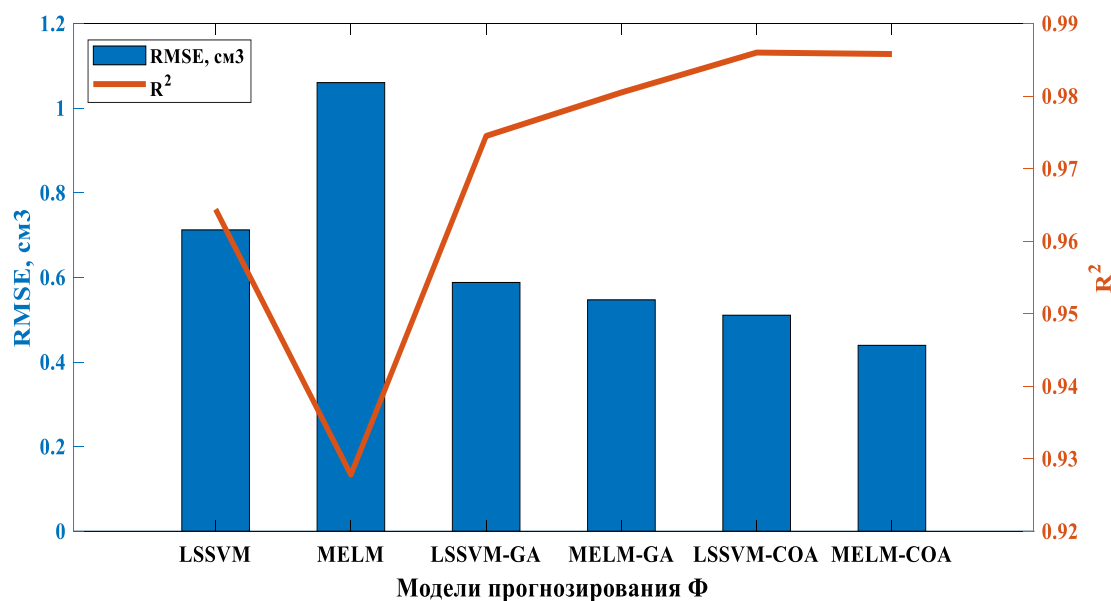


Рисунок 4.2 – Среднеквадратическое отклонение (столбцы) и коэффициент детерминации (линия) для прогнозирования водоотдачи предложенными моделями.

Таким образом, мы приходим к выводу, что значение водоотдачи можно успешно прогнозировать с помощью гибридных моделей МО, использующих в качестве входных параметров только три часто измеряемые входные переменные (плотность, условная вязкость, содержание твердой фазы), тем самым избегая

необходимости проводить многочисленные трудоемкие испытания бурового раствора в полевых условиях. Наличие надежной методики оценки водоотдачи бурового раствора может повысить производительность буровых работ и минимизировать риск повреждения пласта. Это позволит оперативно корректировать кондиционирование бурового раствора в соответствии с изменениями условий бурения и состава бурового раствора в ходе буровых работ. Таблица 4.3 – Результаты оценочного анализа производительности прогнозирования водоотдачи с помощью автономных и гибридных моделей МО.

Модели	Этап	SD	AAPD	APD	RMSE	R ²	Балл	Общий балл
LSSVM	Обучение	2	1	1	2	2	8	17
	Тестирование	2	1	2	2	2	9	
MELM	Обучение	1	2	2	1	1	7	13
	Тестирование	1	2	1	1	1	6	
LSSVM–GA	Обучение	3	3	4	3	3	16	32
	Тестирование	3	3	4	3	3	16	
MELM–GA	Обучение	4	5	6	4	4	23	47
	Тестирование	4	6	6	4	4	24	
LSSVM–COA	Обучение	5	4	3	5	5	22	45
	Тестирование	5	4	3	5	6	23	
MELM–COA	Обучение	6	6	5	6	6	29	56
	Тестирование	6	5	5	6	5	27	

Для дальнейшей оценки эффективности прогнозирования водоотдачи были проведены оценочный анализ (SA) и анализ кривых ошибок регрессии (REC) (раздел 2.4) для прогнозных значений водоотдачи, полученных с помощью разработанных автономных и гибридных моделей МО (таблица 4.3) [143,144]. Модели LSSVM, MELM, LSSVM–GA, MELM–GA, LSSVM–COA и MELM–COA достигли общих оценок эффективности 17, 13, 32, 47, 45, и 56 баллов соответственно.

На рисунке 4.3 графически сравниваются оценки эффективности прогнозирования автономными и гибридными моделями МО значений водоотдачи. Четыре модели, дополненные оптимизаторами, как и предполагалось, показали более высокие баллы как для обучающих, так и для тестовых наборов данных, по сравнению с автономными моделями МО. В частности, общие оценки эффективности прогнозирования водоотдачи посредством автономных моделей MELM и LSSVM составили 13 и 17 баллов, соответственно. Однако общие оценки, полученные гибридными моделями LSSVM–COA и MELM–COA составили 45 и 56 баллов, соответственно; LSSVM–GA и MELM–GA составили 32 и 47 баллов, соответственно. Общая оценка, проведенная по показателям эффективности прогнозирования, достигнутым шестью оцениваемыми моделями, подтверждает, что MELM–COA показывает наиболее точные прогнозы водоотдачи. Далее в порядке понижения общей оценки эффективности следуют MELM–GA, LSSVM–COA, LSSVM–GA, LSSVM и MELM.




Рисунок 4.3 – Диаграмма оценок эффективности прогнозирования для обучающего и тестового наборов данных, а также общий балл (обучение + тестирование), полученный автономными (*LSSVM* и *MELM*) и гибридными моделями МО (*MELM–COA/GA* и *LSSVM–COA/GA*).

На рисунке 4.4 показаны кривые ошибок регрессии (REC) для прогнозных значений водоотдачи, полученных по моделям на основе обучающих и тестовых

наборов данных. В таблице 4.4 приведены значения площади над кривой ошибок регрессии, полученные для каждой из шести моделей.

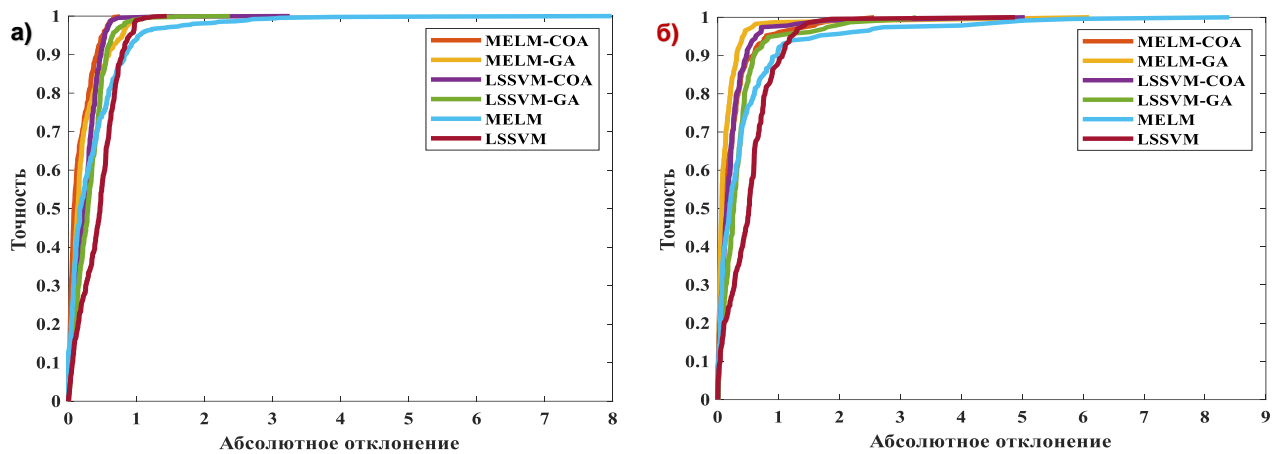


Рисунок 4.4 – Кривые ошибок регрессии (REC) автономных и (LSSVM и MELM) и гибридных (MELM–COA/GA и LSSVM–COA/GA) моделей МО при прогнозировании водоотдачи для: а) обучающего набора данных; и б) тестового набора данных.

Таблица 4.4 – Величины площади над кривыми регрессии REC, полученными при прогнозировании значений водоотдачи с применением автономных (LSSVM и MELM) и гибридных моделей МО (MELM–COA/GA и LSSVM–COA/GA) к обучающим и тестовым наборам данных.

Подмножество/модель	LSSVM	MELM	LSSVM–GA	MELM–GA	LSSVM–COA	MELM–COA
Обучение	0,4391	0,3569	0,3022	0,2227	0,2419	0,1572
Тестирование	0,5204	0,4519	0,3477	0,1586	0,2312	0,2266

Полученные оценки площадей над кривыми регрессии, представленные в таблице 4.4, являются еще одним подтверждением того, что гибридные модели с оптимизаторами более эффективно прогнозируют водоотдачу, чем автономные модели. Это подчеркивает способность оптимизаторов повышать эффективность прогнозирования моделей путем нахождения оптимальных структур и значений гиперпараметров прогнозных моделей (MELM и LSSVM).

Сравнивая значения площади над кривой АОС, полученные по шести изученным моделям, можно видеть, что наиболее точные прогнозы водоотдачи

сгенерированы моделью MELM–COA (обучение = 0,1572, AOC тестирование = 0,1586). С другой стороны, наихудшую эффективность прогнозирования водоотдачи показала автономная модель LSSVM, для которой наблюдаются самые высокие значения AOC (AOC обучения = 0,4391, AOC тестирования = 0,5204). В целом, основываясь на результатах анализа REC и оценочного анализа, модель MELM–COA показала наивысшую эффективность прогнозирования значения водоотдачи. В этой связи разработанные модели MELM–COA могут быть рекомендованы в качестве вычислительного метода для прогнозирования водоотдачи буровых растворов на водной основе по всему интервалу ствола скважины в ходе буровых работ с использованием в качестве входных данных более легкодоступных переменных, таких как плотность, вязкость и содержание твердой фазы. Тем не менее, у других пяти автономных и гибридных моделей МО наблюдается относительно низкая погрешность прогнозирования и хорошая обобщающая способность в части прогнозирования водоотдачи.


4.2. Прогнозирование пластической вязкости

Ниже сравниваются характеристики автономных моделей МО и их гибридных версий с оптимизаторами при прогнозировании пластической вязкости бурового раствора на основе обучающего набора данных (таблица 4.5).

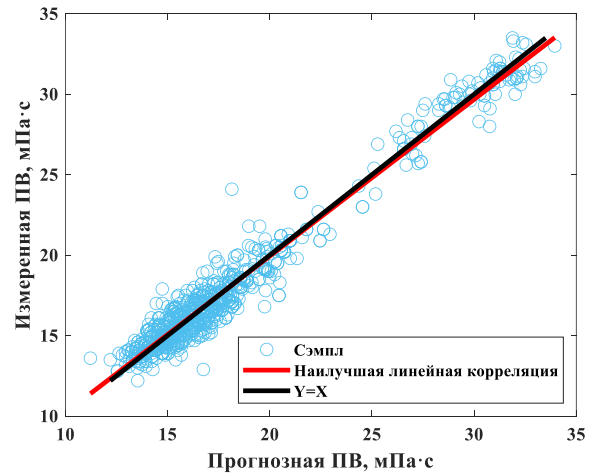
Таблица 4.5 – Погрешности при прогнозировании пластической вязкости, генерируемые автономными и гибридными моделями МО на основе обучающего набора данных.

Тип модели МО	Модель	SD (мПа·с)	AAPD (%)	APD (%)	RMSE (мПа·с)	R ²
Автономные модели	LSSVM	0,4803	2,2062	–0,0529	0,4270	0,9887
	MELM	0,8959	3,9607	–0,0901	0,8954	0,9614
Гибридные модели	LSSVM–GA	0,3283	1,4106	0,1076	0,3290	0,9947
	MELM–GA	0,2966	1,1627	–0,0244	0,2964	0,9957
	LSSVM–COA	0,2713	1,2381	–0,0453	0,2712	0,9964
	MELM–COA	0,2036	0,8884	–0,0158	0,2035	0,9980


На рисунке 4.5 показаны прогнозные и измеренные значения пластической вязкости для обучающего подмножества данных для каждой из двух оцениваемых автономных моделей и четырех гибридных моделей МО.



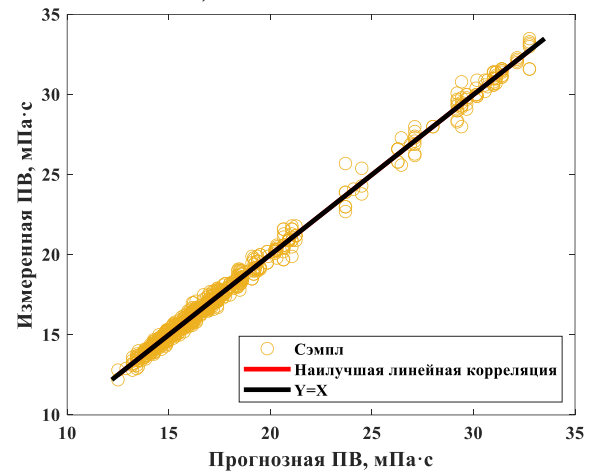
а) Модель LSSVM



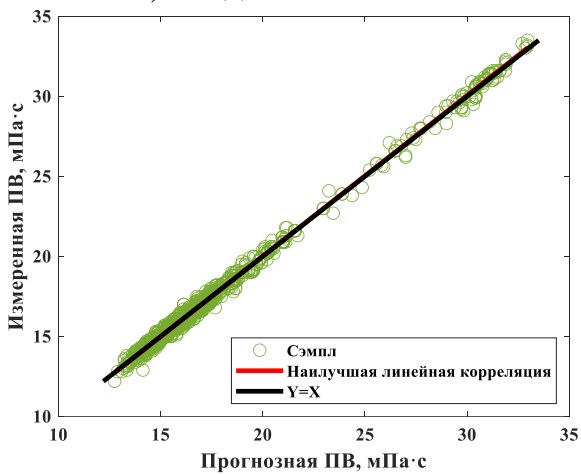
б) Модель MELM



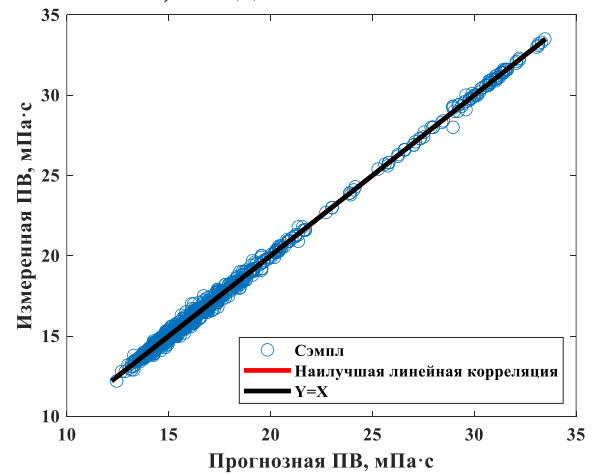
в) Модель LSSVM-GA



г) Модель MELM-GA



д) Модель LSSVM-COA



с) Модель MELM-COA

Рисунок 4.5 – Измеренные и прогнозные значения пластической вязкости, сгенерированные для обучающего подмножества данных двумя оцениваемыми автономными и гибридными моделями МО.

Из рисунка видно, что все шесть разработанных моделей при прогнозировании пластической вязкости почти не проявляют отклонений между линией наилучшего приближения и линией $Y = X$ для прогнозных и измеренных значений. В то время как наблюдается заметное различие между измеренными и прогнозными значениями пластической вязкости, полученными автономной моделью MELM (рисунок 4.5.б), эти различия уменьшаются при использовании прогностических моделей комбинированных с глобальными оптимизаторами (рисунок 4.5.г,д). Следует отметить, что автономная модель LSSVM демонстрирует более точное прогнозирование значений пластической вязкости (рисунок 4.5.а) по сравнению с MELM (рисунок 4.5.б), отличие, которое можно объяснить использованием оптимизационного алгоритма GS. Гибридные модели обеспечивают более высокое качество прогноза при обучении, результаты расчетов демонстрируют меньшую дисперсию вблизи линии $Y-X$ (рисунок 4.5). Модель MELM-COA характеризуется наименьшей дисперсией прогнозных и измеренных значений пластической вязкости (рисунок 4.5), на основании чего можно сделать выводы о ее наибольшем соответствии решаемой

В таблице 4.6 показаны погрешности прогнозирования пластической вязкости, полученные в ходе применения обученных автономных и гибридных моделей к тестовому набору данных.

Таблица 4.6 – Погрешности при прогнозировании пластической вязкости автономными и гибридными моделями МО на основе тестового набора данных.

Тип модели МО	Модель	SD (мПа·с)	AAPD (%)	APD (%)	RMSE (мПа·с)	R ²
Автономные модели	LSSVM	0,7121	3,1424	-0,5112	0,7143	0,9795
	MELM	0,9892	3,8103	-0,3252	0,9874	0,9606
Гибридные модели	LSSVM-GA	0,4607	1,7285	-0,1242	0,4606	0,9916
	MELM-GA	0,4843	1,7129	-0,1095	0,4834	0,9904
	LSSVM-COA	0,3986	1,6487	-0,2637	0,3990	0,9936
	MELM-COA	0,3727	1,2750	0,0685	0,3727	0,9944

Все шесть оцениваемых моделей прогнозируют пластическую вязкость со значениями R^2 выше 0,97 и значениями RMSE ниже 0,99 мПа·с. Полученные результаты подтверждают, что все шесть обученных моделей обеспечивают высокую достоверность прогнозирования пластической вязкости для тестового подмножества данных.

На рисунке 4.6 сравниваются значения RMSE и R^2 , описывающие уровень прогнозирования пластической вязкости каждой из шести обученных моделей. Эффективность прогнозирования пластической вязкости обученными гибридными моделями МО для тестового подмножества данных может быть ранжирована в порядке возрастания значений ошибки RMSE: MELM-COA < LSSVM-COA < LSSVM-GA < MELM-GA, и в порядке возрастания R^2 : MELM-COA > LSSVM-COA > LSSVM-GA > MELM-GA.

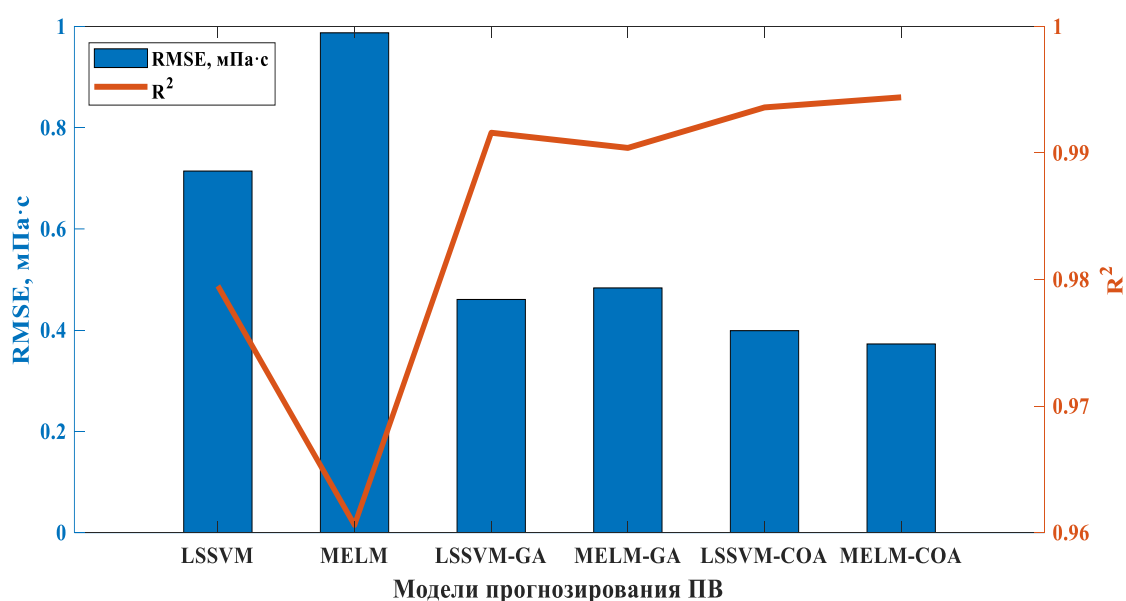


Рисунок 4.6 – Среднеквадратическое отклонение (столбцы) и коэффициент детерминации (линия) для прогнозирования пластической вязкости предложенными моделями.

Таким образом, гибридные модели МО, использующие входные параметры ($\rho_{бр}$, УВ, ТФ), успешно прогнозируют значение пластической вязкости бурового раствора. Это позволяет избежать необходимости проведения трудоемких фильтрационных испытаний в полевых условиях и повышает производительность

буровых работ, особенно в части эффективности выноса бурового шлама и скорости проходки. Оценочный анализ и анализ кривых ошибок регрессии подтверждают эффективность прогнозирования пластической вязкости с использованием разработанных гибридных моделей.

На рисунке 4.7 представлена диаграмма, иллюстрирующая общий балл (таблица 4.7) эффективности прогнозирования пластической вязкости моделями МО.




Рисунок 4.7 – Диаграмма, сравнивающая оценки производительности прогнозирования пластической вязкости для обучающего и тестового подмножеств, полученные двумя оцениваемыми автономными МО (LSSVM и MELM) и гибридными моделями МО (MELM–COA/GA и LSSVM–COA/GA).

Рисунок 4.7 показывает, что все оцененные модели смогли обеспечить высокую точность прогнозирования пластической вязкости как для обучающего, так и для тестового подмножеств. MELM–COA показывает самую высокую оценку эффективности прогнозирования пластической вязкости: 30 для каждого из наборов данных (суммарно 60 баллов), что превосходит аналогичные показатели других пяти оцениваемых моделей. За лидирующей моделью MELM–COA в порядке снижения эффективности следуют модели LSSVM–COA, MELM–GA, LSSVM–GA, LSSVM и MELM.

В таблице 4.7 приведены результаты оценочного анализа эффективности прогнозирования пластической вязкостью с помощью автономных и гибридных моделей МО. Как видно из таблицы 4.7 и рисунка 4.7, автономные модели МО MELM и LSSVM, характеризуются низкими баллами эффективности : 12 и 20 баллов, соответственно. Однако после оптимизации гиперпараметров модели LSSVM–GA, MELM–GA, LSSVM–COA и MELM–COA значительно повышают свою эффективность, достигая 32, 41, 46 и 60 баллов, соответственно.

Таблица 4.7 – Подробная информация о результатах анализа производительности прогнозирования пластической вязкости с помощью автономных и гибридных моделей МО.

Модели	Этап	SD	AAPD	APD	RMSE	R ²	Балл	Общий балл
LSSVM	Обучение	2	2	3	2	2	11	20
	Тестирование	2	2	1	2	2	9	
MELM	Обучение	1	1	2	1	1	6	12
	Тестирование	1	1	2	1	1	6	
LSSVM–GA	Обучение	3	3	1	3	3	13	32
	Тестирование	4	3	4	4	4	19	
MELM–GA	Обучение	4	5	5	4	4	23	41
	Тестирование	3	4	5	3	3	18	
LSSVM–COA	Обучение	5	4	4	5	5	23	46
	Тестирование	5	5	3	5	5	23	
MELM–COA	Обучение	6	6	6	6	6	30	60
	Тестирование	6	6	6	6	6	30	

Тем не менее, гибридные модели показали более высокую эффективность прогнозирования пластической вязкости: в 95% случаев значения абсолютного отклонения составили менее 1 как для обучающих, так и для тестовых подмножеств. Сравнение значений площади над кривой шести оцениваемых моделей, представленное в таблице 4.8, также подтверждает превосходство моделей, дополненных оптимизатором.

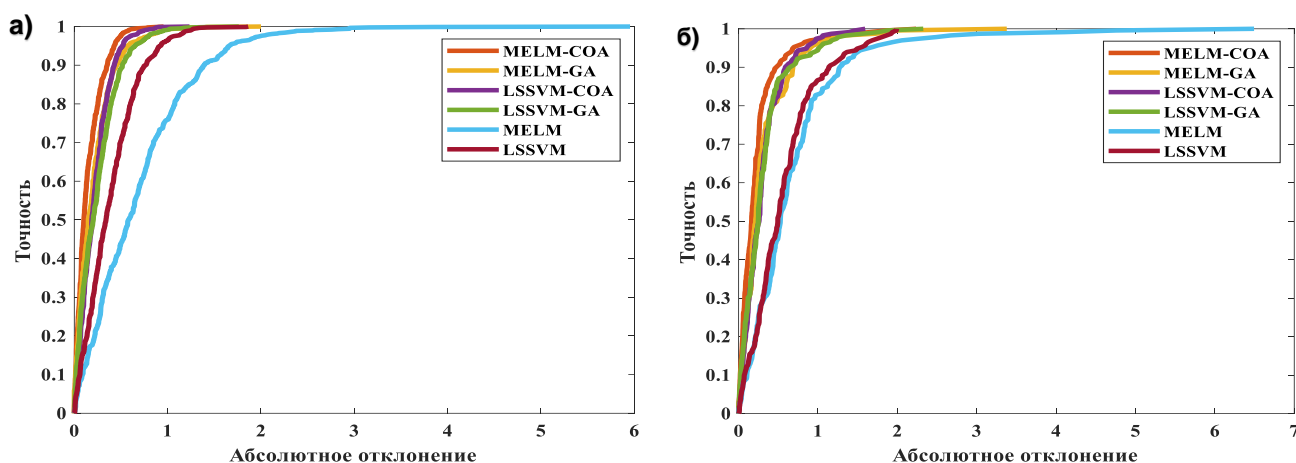


Рисунок 4.8 – Кривые ошибок регрессии автономных (LSSVM и MELM) и гибридных (MELM–COA/GA и LSSVM–COA/GA) моделей МО при прогнозировании пластической вязкости для: а) обучающего подмножества; и б) тестового подмножества данных.

Таблица 4.8 – Соответствующие значения площади над кривой REC для прогнозных значений пластической вязкости, полученных с помощью автономных моделей МО (LSSVM и MELM) и гибридных моделей МО (MELM–COA/GA и LSSVM–COA/GA) для обучающего и тестового подмножеств данных.

Подмножество/модели	LSSVM	MELM	LSSVM–GA	MELM–GA	LSSVM–COA	MELM–COA
Обучение	0,3850	0,6841	0,2434	0,2068	0,2141	0,1471
Тестирование	0,5624	0,6647	0,3078	0,3035	0,2939	0,2262

Наибольшую эффективность прогнозирования демонстрирует модель MELM–COA, которой соответствуют самые низкие значения площади над кривой: 0,1471 и 0,2262 для обучающего и тестового подмножеств, соответственно. Напротив, автономная модель MELM показывает самые высокие значения площади над кривыми регрессии: 0,6841 и 0,6647 соответственно.

Значения площади над кривой, представленные в таблице 4.8, подтверждают более высокую эффективность прогнозирования гибридными моделями МО. Самая эффективная из этих моделей, MELM–COA, может быть рекомендована в качестве вычислительного метода для прогнозирования пластической вязкости буровых растворов на водной основе по исходным переменным: плотности бурового

раствора, условной вязкости и содержания твердой фазы. Тем не менее, остальные пять оцениваемых моделей также обеспечивают высокую обобщаемую способность и точность прогнозирования пластической вязкости буровых растворов на водной основе.


4.3. Прогнозирование динамического напряжения сдвига

Ниже сравниваются характеристики моделей МО (MELM и LSSVM) и их гибридных версий с оптимизаторами (MELM–GA/COA и LSSVM–GA/COA) при прогнозировании динамического напряжения сдвига бурового раствора на этапе обучения модели (Таблица 4.9). Гибридные модели МО при прогнозировании динамического напряжения сдвига генерируют меньшую погрешность, чем автономные модели LSSVM и MELM. Модель MELM–COA обеспечивает более высокую точность прогнозирования динамического напряжения сдвига, чем три прочие гибридные модели, генерируя следующие значения погрешностей: $R^2 = 0,9852$, AAPD = 1,1455 и RMSE = 0,1107 для обучающего подмножества данных.

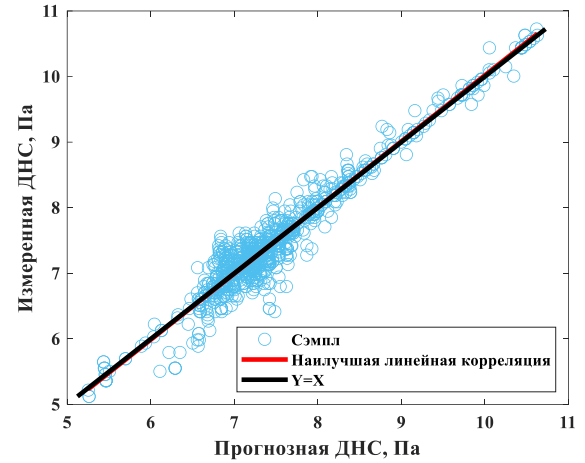
Таблица 4.9 – Погрешности при прогнозировании ДНС, генерируемые автономными и гибридными моделями МО для обучающего подмножества данных.

Тип модели МО	Модель	SD (Па)	AAPD (%)	APD (%)	RMSE (Па)	R ²
Автономные модели	LSSVM	0,1797	1,7512	–0,0548	0,1796	0,9608
	MELM	0,2275	2,1542	–0,1191	0,2274	0,9372
Гибридные модели	LSSVM–GA	0,1426	1,4197	–0,0428	0,1426	0,9753
	MELM–GA	0,1299	1,2836	–0,0328	0,1298	0,9795
	LSSVM–COA	0,1198	1,2475	–0,0389	0,1198	0,9826
	MELM–COA	0,1108	1,1455	–0,0358	0,1107	0,9852


На рисунке 4.9 показаны прогнозные и измеренные значения динамического напряжения сдвига для обучающего подмножества данных для каждой из двух оцениваемых моделей МО и четырех гибридных моделей.




а) Модель LSSVM




б) Модель MELM




в) Модель LSSVM-GA



г) Модель MELM-GA



д) Модель LSSVM-COA



с) Модель MELM-COA

Рисунок 4.9 – Измеренные и прогнозные значения динамического напряжения сдвига, сгенерированные для обучающего подмножества данных оцениваемыми автономными и гибридными моделями МО.

Рисунок 4.9 демонстрирует что автономные модели MELM и LSSVM, хотя и демонстрирую некоторые погрешности в прогнозировании параметра, все же их

результаты вполне хорошо согласуются, как видно по близости линии $Y = X$ к наилучшей подгонке. Однако интеграция глобальных оптимизаторов, таких как GA и COA, существенно улучшает точность моделей. Это улучшение подчеркивается более концентрированным распределением прогнозов на кросс-графиках для гибридных моделей в сравнении с автономными. Обученная модель MELM–COA достигает наибольшей сходимости прогнозных и измеренных значений динамического напряжения сдвига.

Таблица 4.10 – Погрешности при прогнозировании динамического напряжения сдвига с помощью автономных и гибридных моделей МО для тестового подмножества данных.

Тип модели МО	Модель	SD (Па)	AAPD (%)	APD (%)	RMSE (Па)	R ²
Автономные модели	LSSVM	0,2769	2,6546	–0,7890	0,2797	0,9182
	MELM	0,3122	3,0298	–1,0089	0,3167	0,8960
Гибридные модели	LSSVM–GA	0,2505	2,4234	–0,5617	0,2518	0,9327
	MELM–GA	0,2350	2,1094	–0,3898	0,2354	0,9404
	LSSVM–COA	0,2252	2,1161	–0,5503	0,2265	0,9471
	MELM–COA	0,1959	1,8252	–0,4508	0,1970	0,9598

На рисунке 4.10 сравниваются значения RMSE и R², связанные с прогнозами динамического напряжения сдвига для тестового подмножества данных, сгенерированными каждой из шести обученных моделей.

Эффективность прогнозирования динамического напряжения сдвига обученными гибридными моделями МО для тестового подмножества данных может быть ранжирована в порядке возрастания RMSE: MELM–COA < LSSVM–COA < MELM–GA < LSSVM–GA, и в порядке возрастания R²: MELM–COA > LSSVM–COA > MELM–GA > LSSVM–GA.

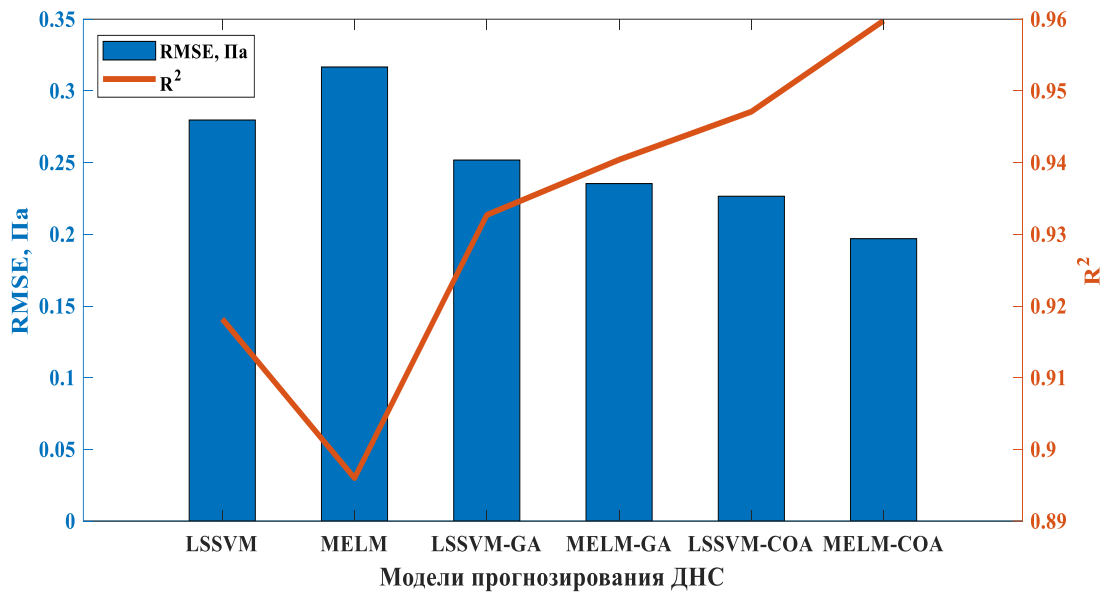


Рисунок 4.10 – Среднеквадратическое отклонение (столбцы) и коэффициент детерминации (линия) для прогнозирования динамического напряжения сдвига предложенными моделями.

Для оценки эффективности прогнозирования динамического напряжения сдвига буровых растворов на водной основе с помощью моделей МО были проведены оценочный анализ (рисунок 4.11) и результаты оценочного анализа при регрессии (таблица 4.11).

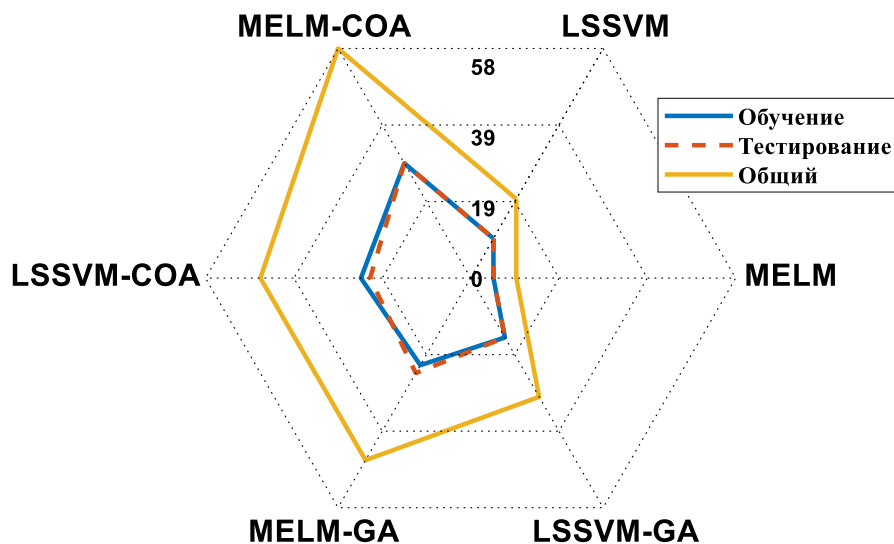


Рисунок 4.11 – Диаграмма, сравнивающая оценки производительности прогнозирования для обучающего и тестового подмножеств, а также общий балл (обучение + тестирование), полученный автономными моделями МО (LSSVM и MELM) и гибридными моделями МО (MELM-COA/GA и LSSVM-COA/GA).

Таблица 4.11 – Подробная информация о результатах анализа производительности динамического напряжения сдвига с помощью автономных и гибридных моделей МО.

Модели	Этап	SD	AAPD	APD	RMSE	R ²	Балл	Общий балл
LSSVM	Обучение	2	2	2	2	2	10	20
	Тестирование	2	2	2	2	2	10	
MELM	Обучение	1	1	1	1	1	5	10
	Тестирование	1	1	1	1	1	5	
LSSVM–GA	Обучение	3	3	3	3	3	15	30
	Тестирование	3	3	3	3	3	15	
MELM–GA	Обучение	4	4	6	4	4	22	46
	Тестирование	5	5	6	4	4	24	
LSSVM–COA	Обучение	5	5	4	5	5	24	46
	Тестирование	4	4	4	5	5	22	
MELM–COA	Обучение	6	6	5	6	6	29	58
	Тестирование	6	6	5	6	6	29	

Автономные модели LSSVM и MELM характеризуются низкими общими баллами эффективности прогнозирования: 20 и 10 баллов соответственно. Гибридные модели LSSVM–GA, MELM–GA, LSSVM–COA и MELM–COA показывают общие оценки эффективности прогнозирования динамического напряжения сдвига 30, 46, 46 и 58 баллов, соответственно. Наиболее эффективная модель MELM–COA достигает оценок эффективности прогнозирования динамического напряжения сдвига 29 и 29 баллов для обучающего и тестового подмножеств, соответственно (рисунок 4.11 и таблица 4.11).

На рисунке 4.12 приведены кривые ошибок регрессии, связанные с погрешностями прогнозирования динамического напряжения сдвига для подмножеств обучения и тестирования.




Рисунок 4.12 – Кривые ошибок регрессии автономных (LSSVM и MELM) и гибридных (MELM–COA/GA и LSSVM–COA/GA) моделей МО при прогнозировании динамического напряжения сдвига для: а) обучающего подмножества; и б) тестового подмножества данных.

В таблице 4.12 приведены соответствующие значения площади над кривой для двух оцениваемых автономных и четырех гибридных моделей МО.

Таблица 4.12 – Значения площади над кривой REC для прогнозных значений динамического напряжения сдвига, полученных с помощью автономных моделей МО (LSSVM и MELM) и гибридных моделей МО (MELM–COA/GA и LSSVM–COA/GA) для обучающего и тестового подмножеств данных.

Подмножество/модель	LSSVM	MELM	LSSVM–GA	MELM–GA	LSSVM–COA	MELM–COA
Обучение	0,1280	0,1540	0,1028	0,0930	0,0901	0,0827
Тестирование	0,1893	0,2134	0,1733	0,1507	0,1518	0,1308

Анализ эффективности прогнозирования динамического напряжения сдвига (рисунок 4.12 и таблица 4.12) подтверждает, что гибридные модели МО (MELM–COA, LSSVM–COA, MELM–GA, LSSVM–GA) более эффективны, чем автономные модели как на обучающих, так и на тестовых выборках данных. Модель MELM–COA показывает самые низкие значения площади над кривой: 0,0827 и 0,1308 для обучающего и тестового подмножеств, соответственно. Напротив, автономная модель MELM показывает самые высокие значения площади над кривой при

прогнозировании динамического напряжения сдвига (обучение: 0,1540 и тестирование: 0,2134).

В этой связи разработанные модели MELM–COA могут быть рекомендованы в качестве вычислительного метода для прогнозирования динамического напряжения сдвига буровых растворов на водной основе по всему интервалу ствола скважины в ходе буровых работ с использованием в качестве входных данных более легкодоступных переменных, таких как плотность, вязкость и содержание твердой фазы. Тем не менее, остальные пять рассмотренных моделей МО также обеспечивают приемлемую точность прогнозирования и обобщаемая способность при расчете прогнозных значений динамического напряжения сдвига.

Результаты настоящего исследования показывают, что динамическое напряжение сдвига может быть достаточно точно спрогнозировано с помощью гибридных моделей МО на основе трех регулярно измеряемых входных переменных (плотности, условной вязкости, содержания твердой фазы), но точность прогнозирования будет уступать точности прогнозирования пластической вязкости. Обеспечение достоверных прогнозов динамического напряжения сдвига в режиме реального времени позволит избежать необходимости проведения многократных трудоемких реологических испытаний бурового раствора в полевых лабораториях. Регулярная и достоверная оценка динамического напряжения сдвига бурового раствора может существенно повысить производительность буровых работ, особенно в части эффективности выноса бурового шлама и скорости проходки. Оперативная оценка водоотдачи, пластической вязкости и динамического напряжения сдвига бурового раствора позволит оперативно корректировать его кондиционирование в соответствии с изменениями условий бурения и состава бурового раствора в ходе буровых работ. Таким образом, открываются возможности для существенного повышения эффективности буровых работ.

4.5. Анализ значимости признаков для наилучшей модели прогнозирования

Оценка чувствительности прогноза модели к изменениям входных данных является важным аспектом для более глубокого понимания поведения использованных модели. Shapley Additive Explanation (SHAP) предоставляет эффективный метод для проведения таких оценок. С использованием методики SHAP можно оценить значимость каждого входного параметра. SHAP присваивает баллы значимости различным характеристикам, раскрывая их вклад в общий прогноз. Эти баллы значимости вычисляются путём анализа всех возможных комбинаций признаков, оценивая изменение выходных данных модели при включении или исключении определённого признака. На основе оценок SHAP построен сводный график, визуализирующий влияния характеристик на общий прогноз.

На Рисунке 4.13 представлены сводный график SHAP (а) и важность признаков для прогнозирования Φ в модели MELM–COA (б). Результаты показывают, что с увеличением значений характеристик их соответствующие значения SHAP уменьшаются (рисунок 4.13а).

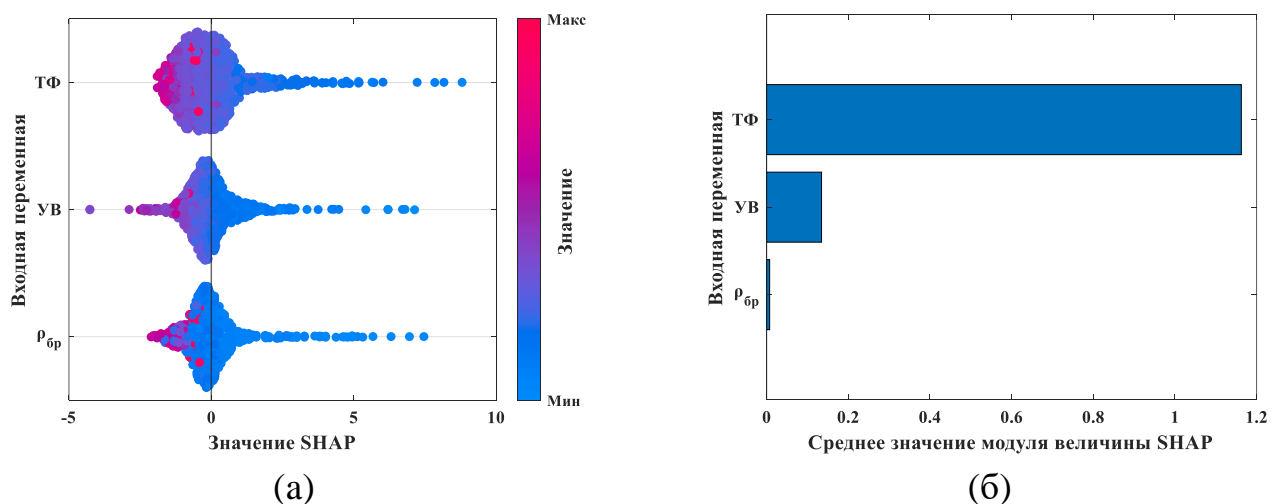


Рисунок 4.13. Оценка влияния признаков на прогноз Φ с использованием модели MELM–COA, как показано значениями SHAP (синий и красный означают минимальные и максимальные значения входных переменных): (а) сводный график SHAP и (б) ранжирование признаков по важности согласно SHAP.

Эта зависимость указывает на то, что более низкие значения характеристик оказывают положительное воздействие на выход модели, в то время как более высокие значения вносят негативный вклад. Более того, можно отметить, что негативное воздействие более высоких значений характеристик менее выражено, чем положительное воздействие более низких значений на прогноз Φ (синий и красный в рисунке 4.12а означают минимальные и максимальные значения входных переменных). В части (рисунк 4.13б) представлена усредненный балл значимости (измеренная абсолютными значениями SHAP) каждой характеристики, упорядоченные по степени их влияния. Здесь наибольшее влияние на прогноз Φ оказывает характеристика ТФ, в то время как наименьшее воздействие на прогнозы модели MELM–COA приходится на характеристику $\rho_{бр}$.

На Рисунке 4.14 показаны сводный график SHAP и важность признаков для разработанной модели MELM–COA, предназначенной для прогноза ПВ.

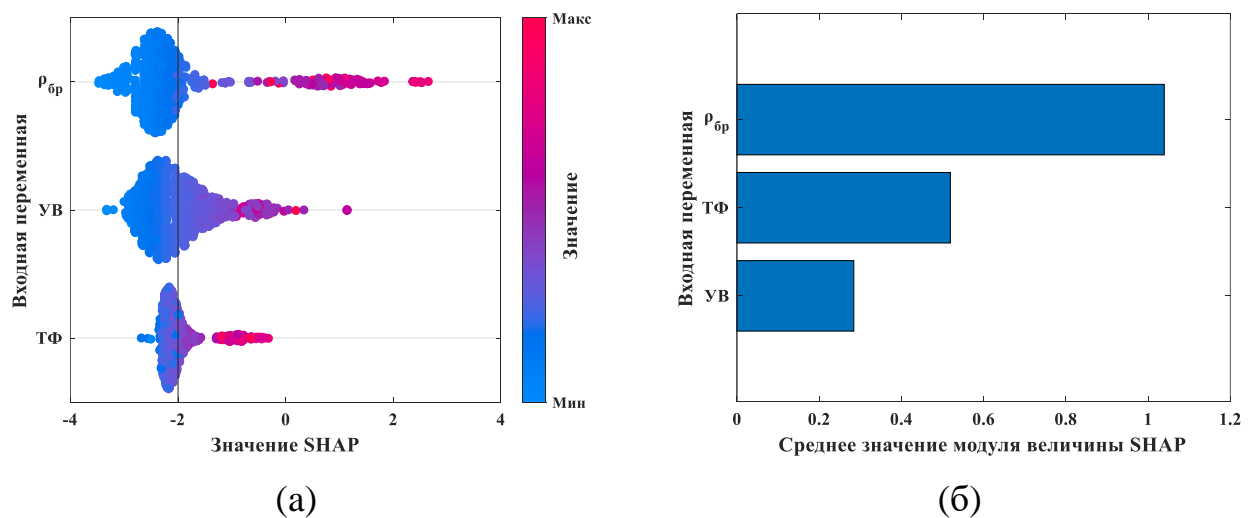


Рисунок 4.14. Оценка влияния признаков на прогноз ПВ с использованием модели MELM–COA, как показано значениями SHAP (синий и красный означают минимальные и максимальные значения входных переменных): (а) сводный график SHAP и (б) ранжирование признаков по важности согласно SHAP.

В части (а) рисунка 4.14 видно, что признаки с низким баллом значимости оказывают негативное влияние на прогнозы ПВ, полученные с помощью модели MELM–COA, тогда как признаки с высоким баллом значимости оказывают положительное воздействие на выход модели (рисунк 4.14, цвет). Распределение

данных показывает, что высокая плотность низких значений признаков сконцентрирована в областях с меньшими значениями SHAP, в то время как области с более высокими положительными значениями SHAP в основном содержат в себе высокие значения признаков. Это распределение говорит о том, что положительное влияние высоких значений признаков на прогноз ПВ выражено более ярко, чем негативное воздействие низких значений признаков. В части (б) Рисунка 4.14, используя средние абсолютные значения SHAP, упорядоченные по значимости, видно, что наибольшее влияние на прогнозы ПВ модели MELM–COA оказывает признак $\rho_{бр}$, тогда как признак УВ имеет минимальное воздействие на прогнозные значения ПВ.

На Рисунке 4.15 представлены сводный график SHAP (а) и значимость характеристик для модели MELM–COA, используемой для прогнозирования ДНС (б).

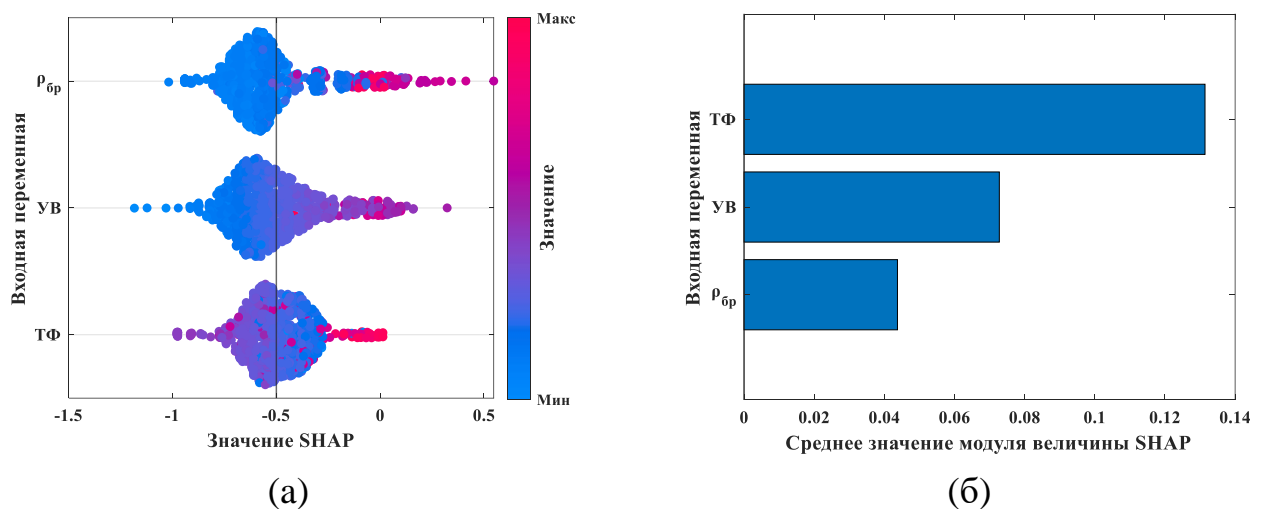


Рисунок 4.15. Оценка влияния признаков на прогноз ДНС с использованием модели MELM–COA, как показано значениями SHAP (синий и красный означают минимальные и максимальные значения входных переменных): (а) сводный график SHAP и (б) ранжирование признаков по важности согласно SHAP.

На Рисунке 4.15.а можно наблюдать, что при низких значениях трех характеристик они имеют отрицательные значения SHAP, в то время как при высоких значениях – положительные. Это говорит о том, что при низких значениях характеристик модель MELM–COA оказывает отрицательное воздействие на

прогноз ДНС, а при высоких значениях – положительное воздействие. Отмечается, что концентрация более низких значений SHAP на меньших значениях характеристик и наличие больших положительных значений SHAP при высоких значениях характеристик позволяют сделать вывод, что положительное влияние высоких значений характеристик на прогноз ДНС превосходит негативное воздействие их низких значений.

Рисунок 4.15b также наглядно демонстрирует, используя средние абсолютные значения SHAP, упорядоченные по значимости, что наибольшее влияние на прогноз ДНС модели MELM–COA оказывает характеристика ТФ, в то время как характеристика $\rho_{бр}$ оказывает наименьшее воздействие на прогнозы ДНС.

4.4. Рекомендации для дальнейшей работы

Результаты настоящего исследования подчеркивают ценность изучения наборов данных по нескольким буровым растворам с помощью гибридных моделей МО для прогнозирования водоотдачи, пластической вязкости и динамического напряжения сдвига буровых растворов на водной основе с использованием легкодоступных параметров в качестве входных переменных. Тем не менее, представленный подход имеет некоторые ограничения:

- Обученные гибридные модели способны прогнозировать водоотдачу, пластическую вязкость и динамическое напряжение сдвига только тех буровых растворах, свойства которых изначально были включены в наборы данных.
- В частности, в наборы данных не вошли параметры буровых растворов,готавливаемых по специальным рецептурам для применения в аномальных условиях бурения.
- В настоящем исследовании также не рассматривается влияние различных присадок на параметры буровых растворов.

В этой связи представляется целесообразным провести дополнительные исследования с изучением наборов данных, охватывающих более широкий спектр типов и рецептур буровых растворов. В частности, необходимо учитывать

специальные буровые растворы для работы в условиях аномального пластового давления и аномальной пластовой температуры. Кроме того, необходимо выделять различные типы добавок и их поверхностные свойства, чтобы обеспечить повышение качества прогнозирования динамического напряжения сдвига для широкого спектра буровых растворов. Эффективность прогнозирования других автономных и гибридных моделей МО также должна быть проверена с использованием баз данных по разнообразным растворам. Комбинация подобных исследований представляет потенциал для обеспечения буровой промышленности более обобщаемыми и надежными моделями для прогнозирования реологии и фильтрационных свойств широкого спектра буровых растворов. Также рекомендуется проведение исследований, посвященных совершенствованию автономных и гибридных моделей МО, предназначенных для оперативной оценки определенных параметров буровых растворов.

Заключение

- Предложена, обоснована и экспериментально проверена прогнозирующая модель, основанная на многослойном экстремальном обучении MELM, обеспечивающая повышение точности прогнозирования свойств бурового раствора с использованием оптимальной архитектуры MELM. Разработанная прогнозирующая модель обеспечивает повышение точности прогнозирования свойств бурового раствора на 35–62% в зависимости от целевого параметра по сравнению с традиционным подходом.
- Предложена, обоснована и экспериментально проверена прогнозирующая модель, основанная на методе опорных векторов LSSVM, обеспечивающая повышение точности прогнозирования свойств бурового раствора путем определения подходящей функции ядра и организации поиска гиперпараметров, при которых достигается глобальный минимум среднеквадратического отклонения. Разработанная прогнозирующая модель обеспечивает повышение точности прогнозирования свойств бурового раствора на 19–45% в зависимости от целевого параметра по сравнению с традиционным подходом.
- Разработанные гибридные модели машинного обучения позволяют прогнозировать водоотдачу, пластическую вязкость и динамическое напряжение сдвига буровых растворов с погрешностями (2,95–4,27)%, (1,27–1,73)% и (1,83–2,42)% соответственно.
- Результаты настоящего диссертационного исследования внедрены в учебный процесс Инженерной школы природных ресурсов ТПУ, а также в производственный процесс компании ООО "Инновационные Технологии". Компаниями были протестированы разработанные в ходе диссертационного исследования модели машинного обучения на реальных данных по буровому раствору ранее пробуренных скважин. Высокая точность прогноза $R^2 \approx 90–92\%$ дала компаниям основание для использования данных моделей при мониторинге бурения скважин с целью повышения точности и

оперативности определения целевых параметров бурового раствора. Акты внедрения приложены к диссертационной работе.

Номенклатура / аббревиатуры

AAPD	Среднее абсолютное процентное отклонение
ИИ	Искусственный интеллект
ANN	Искусственная нейронная сеть
AOC	Площадь над кривой
APD	Среднее процентное отклонение
APE	Абсолютная процентная погрешность
CG	Сопряженный градиент
CNN	Сверточная нейронная сеть
CO ₂	Двуокись углерода
COA	Алгоритм оптимизации Cuckoo
CWT	Комплексное вейвлет–преобразование
ECD	Эквивалентная циркуляционная плотность
ELM	Алгоритм экстремального машинного обучения
ELR	Радиус кладки яиц
FF	Многослойный перцептрон, оптимизированный светлячком
GA	Генетический алгоритм
GD	Градиентный спуск
GMDH	Групповой метод обработки данных
GS	Гравитационный поиск
Grid Search	Алгоритм сеточного поиска
IQR	Межквантильный диапазон
К	Консистенция бурового раствора
lin	Линейная
LSSVM	Метод наименьших квадратов опорных векторов
LSSVM–COA	Метод наименьших квадратов опорных векторов, оптимизированный алгоритмом Cuckoo
LSSVM–GA	Метод наименьших квадратов опорных векторов, оптимизированный генетическим алгоритмом
LSTM	Сеть с долговременной и кратковременной памятью
LSTM–RNN	Рекуррентная нейронная сеть с долговременной и кратковременной памятью
MELM	Метод многослойного экстремального машинного обучения
MELM–COA*	Метод многослойного экстремального машинного обучения, оптимизированный алгоритмом Cuckoo

MELM–GA	Метод многослойного экстремального машинного обучения, оптимизированный генетическим алгоритмом
MO	Машинное обучение
MLP	Многослойный перцептрон
n	Реологическое поведение
R ²	Коэффициент детерминации
RBF	Радиальная базисная функция
REC	Характеристика ошибок регрессии
ReLU	Нелинейная функция активации
RF	Алгоритм «Случайного леса»
RMSE	Среднеквадратичное отклонение
ROP	Скорость проходки
RPM	Скорость вращения, оборотов в минуту
ТФ	Содержание твердой фазы
SA	Оценочный анализ
SD	Стандартное отклонение
SVM	Метод опорных векторов
poly	Полиномиальная
TSFIS	Адаптивная нейро–нечеткая система вывода Такаги–Сугено
XGBoost	Метод экстремального градиентного бустинга
ГП	Гауссовский процесс
УВ	Условная вязкость
ДНС	Динамическое напряжение сдвига
КВ	Кажущаяся вязкость
КВ*	Средняя вязкость
КФР	Кумулятивная функция распределения
ПВ	Пластическая вязкость
$\rho_{б,р}$	Плотность бурового раствора
Ф	Водоотдача
γ	Скорость сдвига
μ	Динамическая вязкость воды
τ	Напряжение сдвига
θ_{300} и θ_{600}	Значение показаний циферблата при скоростях ротора 300 и 600 об/мин

Список использованной литературы

1. Bridges S. A practical handbook for drilling fluids processing / Bridges S, Robinson L.H. - Gulf Professional Publishing, 2020. – 586 p.
2. Khosravian R. Wellbore hydraulics and hole cleaning: optimization and digitalization / Khosravian R., Aadnoy BS. // Methods for Petroleum Well Optimization: Automation and Data Solutions. – Amsterdam: Elsevier, 2021. – P. 149-191.
3. Fink JK. Petroleum engineer's guide to oil field chemicals and fluids / Fink JK. - Amsterdam: Elsevier, 2012. - 785 p.
4. Wang Q. Fluid Chemistry, Drilling and Completion. - Amsterdam: Elsevier, 2021. – 538 p.
5. Ikram R. Towards recent tendencies in drilling fluids: application of carbon-based nanomaterials / Ikram R., Jan B.M., Vejpravova J. // Journal of Materials Research and Technology. – 2021. – Vol. 15. – P. 3733–3758.
6. Davoodi S. Application of a novel acrylamide copolymer containing highly hydrophobic comonomer as filtration control and rheology modifier additive in water-based drilling mud / Davoodi S., Ramazani S.A.A., Soleimani A., [et al.] // Journal of Petroleum Science And Engineering. – 2019. – Vol. 180. – P. 747-755.
7. Ghaderi S. Application of sustainable saffron purple petals as an eco-friendly green additive for drilling fluids: A rheological, filtration, morphological, and corrosion inhibition study / Ghaderi S., Haddadi S.A, Davoodi S., [et al.] // Journal of Molecular Liquids. – 2020. – Vol. 315, Article number 113707
8. Al-Shargabi M. Nanoparticle applications as beneficial oil and gas drilling fluid additives: A review / Al-Shargabi M., Davoodi S., Wood D.A., [et al.] // Journal of Molecular Liquids. – 2022. – Vol. 352, Article number 118725.
9. Hall L.J. Nanocellulose and biopolymer blends for high-performance water-based drilling fluids / Hall L.J., Deville J.P., Santos C.M., [et al.] // IADC/SPE Drilling Conference and Exhibition, Fort Worth, March 6-8, 2018, Article number SPE-189577-MS.

10. Movahedi H. Hydrodynamic analysis and cake erosion properties of a modified water-based drilling fluid by a polyacrylamide/silica nanocomposite during rotating-disk dynamic filtration / Movahedi H., Jamshidi S., Hajipour M. // ACS Omega. – 2022. – Vol. 7, Article number 44240.
11. Ramsey M.S. Rheology, Viscosity, and Fluid Types // Practical Wellbore Hydraulics and Hole Cleaning / Ramsey M.S. - Gulf Professional Publishing, 2019. – P. 217-237.
12. Kariman Moghaddam A. Mesoscopic theoretical modeling and experimental study of rheological behavior of water-based drilling fluid containing associative synthetic polymer, bentonite, and limestone / Kariman Moghaddam A., Davoodi S., Ramazani S.A.A., [et al.] // Journal of Molecular Liquids. – 2022. – Vol. 347, Article number 117950.
13. Davoodi S. Insights into application of acorn shell powder in drilling fluid as environmentally friendly additive: filtration and rheology / Davoodi S., Ramazani A., Rukavishnikov V., [et al.] // International Journal of Environmental Science and Technology. – 2021. – Vol. 18. – P. 835-848.
14. Caenn R. Composition and properties of drilling and completion fluids / Caenn R., Darley H.C.H., Gray G.R. - Gulf Professional Publishing, 2017. – 730 p.
15. Zoveidavianpoor M. Drilling Engineering and Technology - Recent Advances New Perspectives and Applications. Mechanical / Zoveidavianpoor M. – London: IntechOpen, 2022.
16. Davoodi S. A novel field applicable mud formula with enhanced fluid loss properties in High Pressure-High Temperature well condition containing pistachio shell powder / Davoodi S., Ramazani S.A.A, Jamshidi S., [et al.] // Journal of Petroleum Science and Engineering. – 2018. – Vol. 62. – P. 378-385.
17. Deville J.P. Drilling fluids / Deville J.P. // Fluid Chemistry, Drilling and Completion. - Gulf Professional Publishing, 2022. – 115-185.
18. Lavrov A. Lost Circulation: Mechanisms and Solutions / Lavrov A. - Gulf Professional Publishing, 2016. – 252 p.

19. Movahedi H. New insight into the filtration control of drilling fluids using a graphene-based nanocomposite under static and dynamic conditions / Movahedi H., Jamshidi S., Hajipour M. // *ACS Sustainable Chemistry and Engineering*. – 2021. – Vol. 9. – P. 12844- 12857.
20. Kariman Moghaddam A. Rheological modeling of water based drilling fluids containing polymer/bentonite using generalized bracket formalism / Kariman Moghaddam A., Ramazani Saadatabadi A. // *Journal of Petroleum Science and Engineering*. – 2020. – Vol. 189, Article number 107028.
21. Давуди Ш. Сравнительный анализ физических свойств и экономической эффективности буровых растворов с нанодобавками / Давуди Ш., Еремян Г.А., Степико А.В. [и др.] // *Известия Томского политехнического университета. Инжиниринг георесурсов*. - 2021. - Т. 332, № 6. – С.130-141.
22. Jain R. Rheological investigations of water based drilling fluid system developed using synthesized nanocomposite / Jain R., Mahto T.K., Mahto V. // *Korea-Australia Rheology Journal*. – 2016. – Vol. 28. – P. 55–65.
23. Klungtvedt K.R. Preventing drilling fluid induced reservoir formation damage / Klungtvedt K.R., Khalifeh M., Saasen A., [et al.] // *SPE/IADC Middle East Drilling Technology Conference and Exhibition, Abu Dhabi, May 25–27, 2021*. - Society of Petroleum Engineers, 2021, Article number SPE-202187-MS.
24. Siddharth R.C.S. Environmental sustainability of drilling fluids / Siddharth R.C.S., Eswar P.V.S. // *Innovative Exploration Methods for Minerals, Oil, Gas, and Groundwater for Sustainable Development*. – Amsterdam: Elsevier, 2022. – P. 171-176.
25. Davoodi S. Thermally stable and salt-resistant synthetic polymers as drilling fluid additives for deployment in harsh sub-surface conditions: A review / Davoodi S., Al-Shargabi M., Woodc D.A., [et al.] // *Journal of Molecular Liquids*. – 2022. – Vol. 371, Article number 121117.
26. George H.F. Newton’s law of viscosity, newtonian and non-newtonian fluids / George H.F., Qureshi F. // *Encyclopedia of Tribology*. - Boston: Springer, 2013. – P. 2416–2420.

27. Guan Z. *Drilling Fluids* / Guan Z., Chen T., Liao H. // *Theory and technology of drilling engineering*. - Singapore: Springer, 2021. – P. 173–204.
28. Kuma M. The effect of salts and haematite on carboxymethyl cellulose–bentonite and partially hydrolyzed polyacrylamide–bentonite muds for an effective drilling in shale formations / Kuma M., Das B.M., Talukdar P. // *Journal of Petroleum Exploration and Production Technology*. – 2020. – Vol. 10. – P. 395-405.
29. Crespo F. Surge-and-Swab pressure predictions for yield-power-law drilling fluids / Crespo F., Ahmed R., Enfis M., [et al.] // *SPE Drilling and Completion*. – 2012. – Vol. 27, №4. – P. 574-585.
30. Chu Q. Application of a new family of organosilicon quadripolymer as a fluid loss additive for drilling fluid at high temperature / Chu Q., Luo P., Zhao Q., [et al.] // *Journal of Applied Polymer Science*. – 2013. – Vol. 128. – P. 28-40.
31. Shen H. Hydrophobic-associated polymer-based laponite nanolayered silicate composite as filtrate reducer for water-based drilling fluid at high temperature / Shen H., Lv K., Huang X., [et al.] // *Journal of Applied Polymer Science*. – 2020. – Vol. 137, Article number 48608.
32. Mahmoud O. Formation-damage assessment and filter-cake characterization of ca-bentonite fluids enhanced with nanoparticles / Mahmoud O., Nasr-El-Din H.A. // *SPE Drilling and Completion*. – 2021. – Vol. 36, № 1. – P. 75-87.
33. Garrett P.R. The effect of calcium on the foam behaviour of aqueous sodium alkyl benzene sulphonate solutions. (1). In the absence of antifoam / Garrett P.R., Ran L. // *Colloids and Surfaces A: Physicochemical and Engineering Aspects*. – 2017. – Vol. 513. – P. 325-334.
34. Abad A.R.B. Robust hybrid machine learning algorithms for gas flow rates prediction through wellhead chokes in gas condensate fields / Abad A.R.B., Ghorbani H., Mohamadian N., [et al.] // *Fuel*. – 2022. – Vol. 308, Article number 121872.
35. Taheri J. Nano-clays as additives for controlling filtration properties of water – bentonite suspensions / Taheri J., Kanani V., Pourafshary P. // *Journal of Petroleum Science and Engineering*. – 2016. – Vol. 138. – P. 257-264.

36. Elkatatny S. Real-time prediction of rheological parameters of kcl water-based drilling fluid using artificial neural networks / Elkatatny S. // Arabian Journal for Science and Engineering. – 2017. – Vol. 42. – P. 1655-1665.
37. Gowida A. Data-driven framework to predict the rheological properties of cacl2 brine-based drill-in fluid using artificial neural network / Gowida A., Elkatatny S., Ramadan E., [et al.] // Energies. – 2019. – Vol. 12, № 10, Article number 1880.
38. Gul S. Machine learning applications in drilling fluid engineering: a review / Gul S. // ASME 2021 40th International Conference on Ocean, Offshore and Arctic Engineering, Virtual, June 21–30, 2021. – OMAE, 2021. – Vol. 10, Article number OMAE2021-63094.
39. Bangert P. Machine Learning and Data Science in the Oil and Gas Industry: Best Practices, Tools, and Case Studies / Bangert P. - Gulf Professional Publishing, 2021. – 272 p.
40. Badillo S. An introduction to machine learning / Badillo S., Banfai B., Birzele F., [et bal.] // Clinical Pharmacology and Therapeutics. - 2020. – Vol. 107 № 4. – P. 871-885.
41. Osarogiagbon A.U. Review and analysis of supervised machine learning algorithms for hazardous events in drilling operations / Osarogiagbon A.U., Khan F., Venkatesan R., [et al.] // Process Safety and Environmental Protection. – 2021. – Vol. 147. – P. 367-384.
42. Kumar A. A Machine Learning Application for Field Planning / Kumar A. // Offshore Technology Conference, Houston, May 6–9, 2019. – 2019, Article number OTC-29224-MS.
43. Jiajia Z. Prediction method of physical parameters based on linearized rock physics inversion / Jiajia Z., Xingyao Y.I.N., Guangzhi Z., [et al.] // Petroleum Exploration and Development. – 2020. – Vol. 47, № 1. – P. 59–67.
44. Mohamadian N. A geomechanical approach to casing collapse prediction in oil and gas wells aided by machine learning / Mohamadian N., Ghorbani H., Wood D.A., [et al.] // Journal of Petroleum Science and Engineering. – 2021. – Vol. 196, Article number 107811.

45. Sircar A. Application of machine learning and artificial intelligence in oil and gas industry / Sircar A., Yadav K., Rayavarapu K., [et al.] // *Petroleum Research*. – 2021. – Vol. 6, № 4. – P. 379-391.
46. Thanh H.V. Application of hybrid artificial intelligent models to predict deliverability of underground natural gas storage sites / Thanh H.V., Zamanyad A., Safaei-Farouji M., [et al.] // *Renew Energy*. - 2022. – Vol. 200. – P. 169-184.
47. Pandey R.K. Thermodynamic modeling of equilibrium conditions of CH₄/CO₂/N₂ clathrate hydrate in presence of aqueous solution of sodium chloride inhibitor / Pandey R.K., Kakati H., Mandal A. // *Petroleum Science and Technology*. – 2017. – Vol. 35. – P. 947-954.
48. Holditch S.A. Unconventional oil and gas resource development – Let 's do it right / Holditch S.A. // *Journal of Unconventional Oil and Gas Resources*. – 2013. – Vol. 1-2. – P. 2-8.
49. Heghedus C. Advancing deep learning to improve upstream petroleum monitoring / Heghedus C., Shchipanov A., Rong C , [et al.] // *IEEE Access*. – 2019. – Vol. 7. – P. 106248-106259.
50. Andrianova A. Science G. Application of machine learning for oilfield data quality improvement / Andrianova A., Simonov M., Perets D., [et al.] // *SPE Russian Petroleum Technology Conference, Moscow, October 15–17, 2018*. - Society of Petroleum Engineers, 2018, Article number: SPE-191601-18RPTC-MS.
51. Gupta D. A comprehensive study on artificial intelligence in oil and gas sector / Gupta D., Shah M. // *Environmental Science and Pollution Research*. – 2022. – Vol. 29. – P. 50984-50997.
52. Sadiq T. Using neural networks for prediction of formation fracture gradient / Sadiq T., Nashawi I.S. // *SPE/CIM International Conference on Horizontal Well Technology, Calgary, November 6–8, 2000*. - Society of Petroleum Engineers, 2000, Article number SPE-65463-MS.
53. Bello O. Application of artificial intelligence techniques in drilling system design and operations : a state of the art review and future research pathways / Bello O., Teodoriu C., Yaqoob T., [et al.] // *SPE Nigeria Annual International Conference and*

Exhibition, Lagos, August 2–4, 2016. - Society of Petroleum Engineers, 2016, Article number SPE-184320-MS.

54. Sadiq T. Prediction of frictional drag and transmission of slack-off force in horizontal wells using neural networks / Sadiq T., Gharbi R. // SPE Eastern Regional Meeting, Pittsburgh, November 9–11, 1998. - Society of Petroleum Engineers, 1998, Article number SPE-51083-MS. – P. 259-266.

55. Rooki R. Hole cleaning prediction in foam drilling using artificial neural network and multiple linear regression / Rooki R., Doulati Ardejani F., Moradzadeh A. // Geomaterials. – 2014. – Vol. 4, № 1. – P. 47-53.

56. Gidh Y. Artificial neural network drilling parameter optimization system improves ROP by predicting / Gidh Y., Purwanto A., Ibrahim H. // SPE Intelligent Energy International, Utrecht, March 27–29, 2012. - Society of Petroleum Engineers, 2012, Article number SPE-149801-MS.

57. Hajizadeh Y. Machine learning in oil and gas; a SWOT analysis approach / Hajizadeh Y. // Journal of Petroleum Science and Engineering. – 2019. – Vol. 176. – P. 661-663.

58. Subrahmanya N. Advanced machine learning methods for production data pattern recognition / Subrahmanya N., Company E., Xu P., [et al.] // SPE Intelligent Energy Conference & Exhibition, Utrecht, April 1–3, 2014. - Society of Petroleum Engineers, 2014, Article number SPE-167839-MS.

59. Zliobaitė I. An overview of concept drift applications / Zliobaitė I., Pechenizkiy M., Gama J. // Studies in Big Data. – 2015. – Vol. 16. – P. 91-114.

60. Rasheed Khan M. Machine learning derived correlation to determine water saturation in complex lithologies / Rasheed Khan M., Tariq Z., Abdulraheem A. // PE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition 2018, Dammam, April 23–26, 2018. - Society of Petroleum Engineer, 2018, Article number SPE-192307-MS.

61. Ghahfarokhi P.K. A Fiber-optic assisted multilayer perceptron reservoir production modeling : a machine learning approach in prediction of gas production from the marcellus shale / Ghahfarokhi P.K., Carr T., Bhattacharya S., [et al.] //

SPE/AAPG/SEG Unconventional Resources Technology Conference, Houston, July 23–25, 2018. - Society of Petroleum Engineers, 2018, Article number URTEC-2902641-MS.

62. Salem K.G.S.K.G. Prediction of hydraulic properties in carbonate reservoirs using artificial neural network / Salem K.G.S.K.G., Abdulaziz A.A.M.A.M., Dahab A.S.D.A.S.A. // Abu Dhabi International Petroleum Exhibition and Conference, Abu Dhabi, November 12–15, 2018. - Society of Petroleum Engineers, 2018, Article number SPE-193007-MS.

63. Gaurav A. Horizontal shale well EUR determination integrating geology , machine learning , pattern recognition and multivariate statistics focused on the permian basin / Gaurav A. // SPE Liquids-Rich Basins Conference - North America, Midland, September 13–14, 2017. – Society of Petroleum Engineers, 2017, Article number SPE-187494-MS.

64. Zanganeh Kamali M. Permeability prediction of heterogeneous carbonate gas condensate reservoirs applying group method of data handling / Zanganeh Kamali M., Davoodi S., Ghorbani H., [et al] // Marine and Petroleum Geology. – 2022. – Vol. 139, Article number 105597.

65. Behesht Abad A.R. Predicting oil flow rate through orifice plate with robust machine learning algorithms / Behesht Abad A.R., Tehrani P.S., Naveshki M., [et al.] // Flow Measurement and Instrumentation. – 2021. – Vol. 81, article number 102047.

66. Barjouei H.S. Prediction performance advantages of deep machine learning algorithms for two-phase flow rates through wellhead chokes / Barjouei H.S., Ghorbani H., Mohamadian N., [et al.] // Journal of Petroleum Exploration and Production. – 2021. – Vol. 11. – P. 1233-1261.

67. Farsi M. Prediction of oil flow rate through orifice flow meters: Optimized machine-learning techniques / Farsi M., Shojaei Barjouei H., Wood D.A., [et al.] // Measurement. – 2021. – Vol. 174, Article number 108943.

68. Ghorbani H. Adaptive neuro-fuzzy algorithm applied to predict and control multi-phase flow rates through wellhead chokes / Ghorbani H., Wood D.A., Mohamadian N., [et al.] // Flow Measurement and Instrumentation. – 2020. – Vol. 76, Article number 101849.

69. Onwuchekwa C. Application of machine learning ideas to reservoir fluid properties estimation / Onwuchekwa C. // SPE Nigeria Annual International Conference and Exhibition, Lagos, August 6–8, 2018. - Society of Petroleum Engineers, 2018, Article number SPE-193461-MS.

70. Teixeira A.F. Machine learning models to support reservoir production optimization Machine learning models to support reservoir production optimization Alex to reservoir production Machine learning learning models models to support reservoir production optimization opt / Teixeira A.F., Secchi A.R., Argimiro R., [et al.] // IFAC-PapersOnLine. – 2019. – Vol. 52. – P. 498-501.

71. Anifowose F. A parametric study of machine learning techniques in petroleum reservoir permeability prediction by integrating seismic attributes and wireline data / Anifowose F., Abdulraheem A., Al-shuhail A. // Journal of Petroleum Science and Engineering. – 2019. – Vol. 176. – P. 762-774.

72. Nwachukwu A. Fast evaluation of well placements in heterogeneous reservoir models using machine learning / Nwachukwu A., Jeong H., Pyrcz M., [et al.] // Journal of Petroleum Science and Engineering. – 2018. – Vol. 163. – P. 463-475.

73. Sircar A. Application of machine learning and artificial intelligence in oil and gas industry / Sircar A., Yadav K., Rayavarapu K., [et al.] // Petroleum Research. – 2021. – Vol. 6. – P. 379-391.

74. Rashidi S. Determination of bubble point pressure and oil formation volume factor of crude oils applying multiple hidden layers extreme learning machine algorithms / Rashidi S., Mehrad M., Ghorbani H., [et al.] // Journal of Petroleum Science and Engineering. – 2021. – Vol. 202, Article number 108425.

75. Zhang G. A robust approach to pore pressure prediction applying petrophysical log data aided by machine learning techniques / Zhang G., Davoodi S., Shamshirband S., [et al.] // Energy Reports. – 2022. – Vol. 8. – P. 2233-2247.

76. Behesht Abad A.R. Hybrid machine learning algorithms to predict condensate viscosity in the near wellbore regions of gas condensate reservoirs / Behesht Abad A.R., Mousavi S., Mohamadian N., [et al.] // Journal of Natural Gas Science and Engineering. – 2021. – Vol. 95, Article number 104210.

77. Zazoun R.S. Fracture density estimation from core and conventional well logs data using artificial neural networks: The Cambro-Ordovician reservoir of Mesdar oil field, Algeria / Zazoun R.S. // Journal of African Earth Sciences. - 2013. – Vol. 83. – P. 55-73.
78. Ayoub M.A. A new correlation for accurate prediction of oil formation volume factor at the bubble point pressure using Group Method of Data Handling approach / Ayoub M.A., Elhadi A., Fatherlhman D., [et al.] // Journal of Petroleum Science and Engineering. – 2022. – Vol. 208, Part B, Article number 109410.
79. Tabasi S. Optimized machine learning models for natural fractures prediction using conventional well logs / Tabasi S., Soltani Tehrani P., Rajabi M., [et al.] // Fuel. – 2022. – Vol. 326, Article number 124952.
80. Sheykhinasab A. Prediction of permeability of highly heterogeneous hydrocarbon reservoir from conventional petrophysical logs using optimized data-driven algorithms / Sheykhinasab A., Mohseni A.A., Barahooie Bahari A., [et al.] // Journal of Petroleum Exploration and Production Technology. – 2023. – Vol. 13. – P. 661-689.
81. Zhong R. Machine learning for drilling applications: A review / Zhong R., Salehi C., Johnson R. // Journal of Natural Gas Science and Engineering. – 2022. – Vol. 108, Article number 104807.
82. Fruhwirth R.K. Hybrid simulation using neural networks to predict drilling hydraulics in real time / Fruhwirth R.K., Thonhauser G., Mathis W. // SPE Annual Technical Conference and Exhibition, San Antonio, September 24–27, 2006. - Society of Petroleum Engineers, 2006, Article number SPE-103217-MS.
83. Wang Y. Drilling hydraulics optimization using neural networks / Wang Y., Salehi S. // SPE Digital Energy Conference and Exhibition, Woodlands, March 3–5, 2015. - Society of Petroleum Engineers, 2015, Article number SPE-173420-MS.
84. Erge O. Combining physics-based and data-driven modeling in well construction: Hybrid fluid dynamics modeling / Erge O., van Oort E. // Journal of Natural Gas Science and Engineering. – 2022. – Vol. 97, Article number 104348.

85. Rooki R. Estimation of pressure loss of herschel–bulkley drilling fluids during horizontal annulus using artificial neural network / Rooki R. // *Journal of Dispersion Science and Technology*. – 2014. – Vol. 36. – P. 161-169.
86. Barati-Harooni A. Prediction of frictional pressure loss for multiphase flow in inclined annuli during Underbalanced Drilling operations / Barati-Harooni A., Najafi-Marghmaleki A., Tatar A., [et al.] // *Natural Gas Industry B*. – 2016. – Vol. 3. – P. 275-282.
87. Ozbayoglu E.M. Analysis of bed height in horizontal and highly-inclined wellbores by using artificial neural networks / Ozbayoglu E.M., Miska S.Z., Reed T., [et al.] // *SPE International Thermal Operations and Heavy Oil Symposium and International Horizontal Well Technology Conference*, Calgary, November 4-7, 2002. - Society of Petroleum Engineers, 2002, Article number SPE-78939-MS.
88. Kamyab M. A New method to determine friction factor of cuttings slip velocity calculation in vertical wells using neural networks / Kamyab M., Dawson R., Farmanbar P. // *SPE Asia Pacific Oil & Gas Conference and Exhibition*, Perth, October 25-27, 2016. - Society of Petroleum Engineers, 2016, Article number SPE-182359-MS.
89. Bajolvand M. Optimization of controllable drilling parameters using a novel geomechanics-based workflow / Bajolvand M., Ramezanzadeh A., Mehrad M., [et al.] // *Journal of Petroleum Science and Engineering*. – 2022. – Vol. 218, Article number 111004.
90. Jafarizadeh F. A new robust predictive model for lost circulation rate using convolutional neural network: A case study from Marun Oilfield / Jafarizadeh F., Larki B., Kazemi B., [et al.] // *Petroleum*. - 2022. – Vol. 9, № 3. – P. 468-485.
91. Al-Azani K. Cutting concentration prediction in horizontal and deviated wells using artificial intelligence techniques / Al-Azani K., Elkatatny S., Ali A., [et al.] // *Journal of Petroleum Exploration and Production Technology*. - 2019. – Vol. 9. – P. 2769-2779.
92. Kumar A. Machine learning methods for herschel-bulkley fluids in annulus: Pressure drop predictions and algorithm performance evaluation / Kumar A., Ridha S., Ganet T., [et al.] // *Applied Sciences*. – 2020. – Vol. 10, Article number 2588.

93. Osarogiagbon A. A new methodology for kick detection during petroleum drilling using long short-term memory recurrent neural network / Osarogiagbon A., Muojeke S., Venkatesan R., [et al.] // *Process Safety and Environmental Protection*. – 2020. – Vol. 142. – P. 126-137.
94. Davoodi S. Hybridized machine-learning for prompt prediction of rheology and filtration properties of water-based drilling fluids / Davoodi S., Mehrad M., Wood D.A., [et al.] // *Engineering Applications of Artificial Intelligence*. – 2023. – Vol. 123, Part C, Article number 106459.
95. Zamanzadeh Talkhouncheh M. A new approach to mechanical brittleness index modeling based on conventional well logs using hybrid algorithms / Zamanzadeh Talkhouncheh M., Davoodi S., Larki B., [et al.] // *Earth Science Informatics*. – 2023. – Vol. 1. – P. 1–30.
96. Третьяк А.Я. Нейросетевое прогнозирование реологических параметров бурового раствора / Третьяк А.Я., Кузнецова А.В., Борисов К.А, [и др.] // *Известия ТПУ. Инжиниринг георесурсов*. – 2022. – Т. 333, № 8. – С.163-173.
97. Ismail A. Characterization based machine learning modeling for the prediction of the rheological properties of water-based drilling mud: an experimental study on grass as an environmental friendly additive / Ismail A., Rashid H.M.A., Gholami R., [et al.] // *Journal of Petroleum Exploration and Production Technology*. – 2022. – Vol. 12. – P. 1677-1695.
98. Elkatatny S. Real time prediction of drilling fluid rheological properties using Artificial Neural Networks visible mathematical model (white box) / Elkatatny S., Tariq Z., Mahmoud M. // *Journal of Petroleum Science and Engineering*. – 2016. – Vol. 146. – P. 1202-1210.
99. Alsabaa A. Real-time prediction of rheological properties of invert emulsion mud using adaptive neuro-fuzzy inference system / Alsabaa A., Gamal H., Elkatatny S., [et al.] // *Sensors*. – 2020. – Vol. 20, № 6, Article number 1669.
100. Al-Azani K. Real time prediction of the rheological properties of oil-based drilling fluids using artificial neural networks / Al-Azani K., Elkatatny S., Abdulraheem A., [et al.] // *SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition*

2018, Dammam, April 23–26, 2018. - Society of Petroleum Engineer, 2018, Article number SPE-192199-MS.

101. Elkatatny S. A new approach to determine the rheology parameters for water-based drilling fluid using artificial neural network / Elkatatny S., Mousa T., Mahmoud M. // SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition 2018, Dammam, April 23–26, 2018. - Society of Petroleum Engineer, 2018, Article number SPE-192190-MS.

102. Elkatatny S. Artificial neural network models for real-time prediction of the rheological properties of NaCl mud / Elkatatny S. // Arabian Journal of Geosciences. – 2020, Vol. 13, Article number 257.

103. Golsefatan A. A comprehensive modeling in predicting the effect of various nanoparticles on filtration volume of water-based drilling fluids / Golsefatan A., Shahbazi K. // Journal of Petroleum Exploration and Production Technology. - 2020. – Vol. 10. – P. 859-870.

104. Gomaa I. Real-time determination of rheological properties of high over-balanced drilling fluid used for drilling ultra-deep gas wells using artificial neural network / Gomaa I., Elkatatny S., Abdulraheem A. // Journal of Natural Gas Science and Engineering. – 2020. – Vol. 77, Article number 103224.

105. Razi M.M. Artificial neural network modeling of plastic viscosity, yield point, and apparent viscosity for water-based drilling fluids / Razi M.M., Mazidi M., Razi F.M., [et al.] // Journal of Dispersion Science and Technology. - 2013. – Vol. 34, № 6. – P. 822-827.

106. Tomiwa O. Improved water based mud using solanum tuberosum formulated biopolymer and application of artificial neural network in predicting mud rheological properties / Tomiwa O., Oluwatosin R., Temiloluwa O., [et al.] // SPE Nigeria Annual International Conference and Exhibition, Lagos, August 5-7, 2019. – Society of Petroleum Engineers, 2019, Article number SPE-198861-MS.

107. Golsefatan A. Predicting performance of SiO₂ nanoparticles on filtration volume using reliable approaches: application in water-based drilling fluids / Golsefatan

A., Shahbazi K. // Energy Sources, Part A: Recovery, Utilization, and Environmental Effects. – 2021. – Vol. 43, № 23. – P. 3216-3225.

108. Lekomtsev A. On the prediction of filtration volume of drilling fluids containing different types of nanoparticles by ELM and PSO-LSSVM based models / Lekomtsev A., Keykhosravi A., Moghaddam M.B., [et al.] // Petroleum. – 2022. – Vol. 8, № 3. – P. 424-435.

109. Gul S. A machine learning approach to filtrate loss determination and test automation for drilling and completion fluids / Gul S., van Oort E. // Journal of Petroleum Science and Engineering. – 2020. – Vol. 186, Article number 106727.

110. Jin M. Hyperparameter Tuning of artificial neural networks for well production estimation considering the uncertainty in initialized parameters / Jin M., Liao Q., Patil S., [et al.] // ACS Omega. – 2022. – Vol. 7. – P. 24145-24156.

111. Rajabi M. Predicting shear wave velocity from conventional well logs with deep and hybrid machine learning algorithms / Rajabi M., Hazbeh O., Davoodi S., [et al.] // Journal of Petroleum Exploration and Production Technology. – 2022. – Vol. 13. – P. 19-42.

112. Farsi M. Predicting formation pore-pressure from well-log data with hybrid machine-learning optimization algorithms / Farsi M., Mohamadian N., Ghorbani H., [et al.] // Natural Resources Research. - 2021. – Vol. 30. – P. 3455-3481.

113. Anemangely M. Machine learning technique for the prediction of shear wave velocity using petrophysical logs / Anemangely M., Ramezanzadeh A., Amiri H., [et al.] // Journal of Petroleum Science and Engineering. – 2019. – Vol. 174. – P. 306-327.

114. Sabah M. Hybrid machine learning algorithms to enhance lost-circulation prediction and management in the Marun oil field / Sabah M., Mehrad M., Ashrafi S.B., [et al.] // Journal of Petroleum Science and Engineering. – 2021. – Vol. 198, Article number 108125.

115. Mehrad M. Estimating shear wave velocity in carbonate reservoirs from petrophysical logs using intelligent algorithms / Mehrad M., Ramezanzadeh A., Bajolvand M., [et al.] // Journal of Petroleum Science and Engineering. – 2022. – Vol. 212, Article number 110254.

116. Matinkia M. Developing a New Model for Drilling Rate of Penetration Prediction Using Convolutional Neural Network / Matinkia M., Sheykhinasab A., Shojaei S., [et al.] // *Arabian Journal for Science and Engineering*. - 2022. – Vol. 47. – P. 11953-11985.
117. Matinkia M. Prediction of permeability from well logs using a new hybrid machine learning algorithm / Matinkia M., Hashami R., Mehrad M., [et al.] // *Petroleum*. - 2022. – Vol. 9, № 1. – P. 108-123.
118. Matinkia M. A novel approach to pore pressure modeling based on conventional well logs using convolutional neural network / Matinkia M., Amraeiniya A., Behboud M.M., [et al.] // *Journal of Petroleum Science and Engineering*. – 2022. – Vol. 211, Article number 110156.
119. Ahmadi M.A. Evolving smart approach for determination dew point pressure through condensate gas reservoirs / Ahmadi M.A., Ebadi M. // *Fuel*. – 2014. – Vol. 117. – P. 1074-1084.
120. Ahmadi M.A. Connectionist model for predicting minimum gas miscibility pressure: Application to gas injection process / Ahmadi M.A., Zahedzadeh M., Shadizadeh S.R., [et al.] // *Fuel*. – 2015. – Vol. 148. – P. 202-211.
121. Ahmadi M.A. Prediction of a solid desiccant dehydrator performance using least squares support vector machines algorithm / Ahmadi M.A., Lee M., Bahadori A. // *Journal of the Taiwan Institute of Chemical Engineers*. – 2015. – Vol. 50. – P. 115–122.
122. Wei J. New imbalanced fault diagnosis framework based on Cluster-MWMOTE and MFO-optimized LS-SVM using limited and complex bearing data / Wei J., Huang H., Yao L., [et al.] // *Engineering Applications of Artificial Intelligence*. – 2020. – Vol. 96, Article number 103966.
123. Li Y. Short-term wind speed forecasting based on improved ant colony algorithm for LSSVM / Li Y., Yang P., Wang H. // *Cluster Computing*. – 2019. – Vol. 22. – P. 11575-11581.
124. Zhang Y. Short term wind energy prediction model based on data decomposition and optimized LSSVM / Zhang Y., Li R. // *Sustainable Energy Technologies and Assessments*. – 2022. – Vol. 52, Article number 102025.

125. Davoodi S. Machine-learning models to predict hydrogen uptake of porous carbon materials from influential variables / Davoodi S., Vo Thanh H., Wood D.A., [et al.] // *Separation and Purification Technology*. – 2023. – Vol. 316, Article number 123807.

126. Davoodi S. Combined machine-learning and optimization models for predicting carbon dioxide trapping indexes in deep geological formations / Davoodi S., Vo Thanh H., Wood D.A., [et al.] // *Applied Soft Computing*. – 2023. – Vol. 143, Article number 110408.

127. Liang N.Y. A fast and accurate online sequential learning algorithm for feedforward networks / Liang N.Y., Huang G. Bin, Saratchandran P., [et al.] // *IEEE Trans Neural Networks*. – 2006. – Vol. 17. – P. 1411-1423.

128. Yeom C.U. Short-term electricity-load forecasting using a task-based extreme learning machine with knowledge representation / Yeom C.U., Kwak K.C. // *Energies*. – 2017. – Vol. 10, № 10, Article number 1613.

129. Pan L. Research on gear fault diagnosis based on feature fusion optimization and improved two hidden layer extreme learning machine / Pan L., Zhao L., Song A., [et al.] // *Measurement*. – 2021. – Vol. 177, Article number 109317.

130. Liu J. Random search enhancement of incremental regularized multiple hidden layers ELM / Liu J., Liu X., Liu C., [et al.] // *IEEE Access*. – 2019. – Vol. 7. – P. 36866-36878.

131. Beheshtian S. Robust computational approach to determine the safe mud weight window using well-log data from a large gas reservoir / Beheshtian S., Rajabi M., Davoodi S., [et al.] // *Marine and Petroleum Geology*. – 2022. – Vol. 142, Article number 105772.

132. Rajabioun R. Cuckoo optimization algorithm / Rajabioun R. // *Applied Soft Computing*. – 2011. – Vol. 11, № 8. – P. 5508-5518.

133. Addeh J. Statistical process control using optimized neural networks: A case study / Addeh J., Ebrahimzadeh A., Azarbad M., [et al.] // *ISA Transactions*. – 2014. – Vol. 53, № 5. – P. 1489–1499.

134. Roozitalab A. Optimizing the warranty period by cuckoo meta-heuristic algorithm in heterogeneous customers' population / Roozitalab A., Asgharizadeh E. // *Journal of Industrial Engineering International*. – 2013. – Vol. 9, Article number 27.
135. Mellal M.A. Parameter optimization of advanced machining processes using cuckoo optimization algorithm and hoopoe heuristic / Mellal M.A., Williams E.J. // *Journal of Intelligent Manufacturing*. – 2016. – Vol. 27. – P. 927-942.
136. Jalae S.A. Forecasting Iran's energy demand using cuckoo optimization algorithm / Jalae S.A., Ghaseminejad A., Lashkary M., [et al.] // *Mathematical Problems in Engineering*. – 2019. – Vol. 2019, Article number 2041756.
137. Akbari M. Hybrid approach based on cuckoo optimization algorithm and genetic algorithm for task scheduling / Akbari M. // *Evolutionary Intelligence*. – 2021. – Vol. 14. – P. 1931-1947.
138. Makeen P. Experimental and Theoretical Analysis of the Fast Charging Polymer Lithium-Ion Battery Based on Cuckoo Optimization Algorithm (COA) / Makeen P., Ghali H.A., Memon S. // *IEEE Access*. – 2020. – Vol. 8. – P. 140486-140496.
139. Bahmani M. A novel approach to forecast global CO2 emission using Bat and Cuckoo optimization algorithms / Bahmani M., GhasemiNejad A., Robati F.N., [et al.] // *MethodsX*. – 2020. – Vol. 7, Article number 100986.
140. Yang X.S. Nature-inspired optimization algorithms: Challenges and open problems / Yang X.S. // *Journal of Computational Science*. – 2020. – Vol. 46, Article number 101104.
141. Cai Z. Prediction of landslide displacement based on GA-LSSVM with multiple factors / Cai Z., Xu W., Meng Y., [et al.] // *Bulletin of Engineering Geology and the Environment*. – 2016. – Vol. 75. – P. 637-646.
142. Zhou L. Prediction of CO2 adsorption on different activated carbons by hybrid group method of data-handling networks and LSSVM / Zhou L. // *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*. – 2019. – Vol. 41. – P. 1960-1971.

143. Asteris P.G. Predicting concrete compressive strength using hybrid ensembling of surrogate machine learning models / Asteris P.G., Skentou A.D., Bardhan A., [et al.] // *Cement and Concrete Research*. – 2021. – Vol. 145, Article number 106449.
144. Azam A. Modeling resilient modulus of subgrade soils using LSSVM optimized with swarm intelligence algorithms / Azam A., Bardhan A., Kaloop M.R., [et al.] // *Scientific Reports*. - 2022 - Vol. 12, Article number 14454.
145. Ahmadi M.A. Evolving artificial neural network and imperialist competitive algorithm for prediction oil flow rate of the reservoir / Ahmadi M.A., Ebadi M., Shokrollahi A., [et al.] // *Applied Soft Computing*. – 2013. – Vol. 13. – P. 1085-1098.
146. Sun J. Synthesis of hydrophobic associative polymers to improve the rheological and filtration performance of drilling fluids under high temperature and high salinity conditions / Sun J., Zhang X., Lv K., [et al.] // *Journal of Petroleum Science and Engineering*. – 2022. – Vol. 209, Article number 109808.
147. Liu F. Poly(ionic liquids) based on β -cyclodextrin as fluid loss additive in water-based drilling fluids / Liu F., Wang X., Li X., Dai X., [et al.] // *Journal of Molecular Liquids*. – 2022. – Vol. 350, Article number 118560.
148. Seyyedattar M. Determination of bubble point pressure and oil formation volume factor: Extra trees compared with LSSVM-CSA hybrid and ANFIS models / Seyyedattar M., Ghiasi M.M., Zendehboudi S., [et al.] // *Fuel*. – 2020. – Vol. 269, Article number 116834.
149. Ashrafi S.B. Application of hybrid artificial neural networks for predicting rate of penetration (ROP): A case study from Marun oil field / Ashrafi S.B., Anemangely M., Sabah M., [et al.] // *Journal of Petroleum Science and Engineering*. – 2019. – Vol. 175. – P. 604-623.
150. Alizadeh S.M. An insight into the estimation of drilling fluid density at HPHT condition using PSO-, ICA-, and GA-LSSVM strategies / Alizadeh S.M., Alruyemi I., Daneshfar R., [et al.] // *Scientific Reports*. – 2021. – Vol. 11, Article number 7033.
151. Saporetta C.M. Hybrid Unsupervised Extreme Learning Machine Applied to Facies Identification / Saporetta C.M., Rosa I.G.L., Carvalho R.M., [et al.] // *Proceedings*

of Research and Applications in Artificial Intelligence. – Singapore: Springer, 2021. – Vol. 1355. – P. 319-326.

152. Delavar M.R. Hybrid machine learning approaches for classification and detection of fractures in carbonate reservoir / Delavar M.R. // *Journal of Petroleum Science and Engineering*. - 2022. – Vol. 208, Article number 109327.

153. Shayan Nasr M. Application of Artificial Intelligence to Predict Enhanced Oil Recovery Using Silica Nanofluids / Shayan Nasr M., Shayan Nasr H., Karimian M., [et al.] // *Natural Resources Research*. – 2021. – Vol. 30. – P. 2529-2542. <https://doi.org/10.1007/s11053-021-09829-1>.

154. Goltapeh S.A. Artificial neural network-based caprock structural reliability analysis for co2 injection site - an example from northern north sea / Goltapeh S.A., Rahman M.J., Mondol N.H., [et al.] // *Energies*. – 2022. – Vol. 15, № 9, Article number 3365.

155. Bai T. Hybrid geological modeling: Combining machine learning and multiple-point statistics / Bai T., Tahmasebi P. // *Computers and Geosciences*. – 2020. – Vol. 142, Article number 104519.

156. Mehrad M. Developing a new rigorous drilling rate prediction model using a machine learning technique / Mehrad M., Bajolvand M., Ramezanzadeh A., [et al.] // *Journal of Petroleum Science and Engineering*. – 2020. – Vol. 192, Article number 107338.

157. Jiang F. A clustering-based ensemble approach with improved pigeon-inspired optimization and extreme learning machine for air quality prediction / Jiang F., He J., Tian T. // *Applied Soft Computing*. – 2019. – Vol. 85, Article number 105827. <https://doi.org/10.1016/J.ASOC.2019.105827>.

158. Seyyedattar M. Relative permeability modeling using extra trees, ANFIS, and hybrid LSSVM–CSA methods / Seyyedattar M., Zendehboudi S., Butt S. // *Natural Resources Research*. – 2021. – Vol. 31. – P. 571-600.

159. Lariche M.J., Developing supervised models for estimating methylene blue removal by silver nanoparticles / Lariche M.J., Soltani S., Davoudi Nezhad, H., [et al.] //

Energy Sources, Part A: Recovery, Utilization, and Environmental Effects. – 2020. – Vol. 42. – P. 1247-1254.

160. Mahdaviara M. Modeling relative permeability of gas condensate reservoirs: Advanced computational frameworks / Mahdaviara M., Menad N.A., Ghazanfari M.H., [et al.] // Journal of Petroleum Science and Engineering. – 2020. – Vol. 189, Article number 106929.

161. Davoodi S. Machine-learning predictions of solubility and residual trapping indexes of carbon dioxide from global geological storage sites / Davoodi S., Vo Thanh H., Wood D.A., [et al.] // Expert Systems with Applications. – 2023. – Vol. 222, Article number 119796.

162. Piroozian A. Impact of drilling fluid viscosity, velocity and hole inclination on cuttings transport in horizontal and highly deviated wells / Piroozian A., Ismail I., Yaacob Z., [et al.] // Journal of Petroleum Exploration and Production Technology. – 2012. – Vol. 2. – P. 149-156.

163. Mao H. Conceptual design and methodology for rheological control of water-based drilling fluids in ultra-high temperature and ultra-high pressure drilling applications / Mao H., Yang Y., Zhang H., [et al.] // Journal of Petroleum Science and Engineering. – 2020. – Vol. 188, Article number 106884.

164. Bageri B.S. Effect of Different Weighting Agents on Drilling Fluids and Filter Cake Properties in Sandstone Formations / Bageri B.S., Gamal H., Elkatatny S., [et al.] // ACS Omega. – 2021. – Vol. 6. – P. 16176-16186.

165. Ahmad H.M. High molecular weight copolymers as rheology modifier and fluid loss additive for water-based drilling fluids / Ahmad H.M., Kamal M.S., Al-Harathi M.A. // Journal of Molecular Liquids. – 2018. – Vol. 252. – P. 133-143.

Приложение А

Свидетельства о государственной регистрации программ для ЭВМ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2022685136

Программа для расчета фильтрационных свойств
бурового раствора на основе гибридной модели
машинного обучения MELM-COA

Правообладатель: *Давуди Шадфар (RU)*

Автор(ы): *Давуди Шадфар (RU)*

Заявка № 2022684195

Дата поступления 05 декабря 2022 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 21 декабря 2022 г.



Руководитель Федеральной службы
по интеллектуальной собственности

Документ подписан электронной подписью
Сертификат 68b89037614e4910a94edbd24145d5c7
Владимир Зубов Юридический Сервис
Действителен с 01.01.2022 по 30.03.2025

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2023611146

**Программа для расчета пластической вязкости бурового
раствора на основе гибридной модели машинного
обучения MELM-COA**

Правообладатель: *Давуди Шадфар (RU)*

Автор(ы): *Давуди Шадфар (RU)*



Заявка № **2022685740**

Дата поступления **16 декабря 2022 г.**

Дата государственной регистрации

в Реестре программ для ЭВМ **17 января 2023 г.**

*Руководитель Федеральной службы
по интеллектуальной собственности*

документ подписан электронной подписью
Сертификат 68e8007b14e4010a34c6bd24145d5c7
Владельцу: **Зубов Юрий Сергеевич**
Действителен с 20.05.2022 по 25.05.2025

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2023610692

**Программа для расчета динамического напряжения
сдвига бурового раствора на основе модели машинного
обучения MELM-SOA**

Правообладатель: *Давуди Шадфар (RU)*

Автор(ы): *Давуди Шадфар (RU)*



Заявка № 2022685760

Дата поступления 16 декабря 2022 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 12 января 2023 г.

*Руководитель Федеральной службы
по интеллектуальной собственности*

документ подписан электронной подписью
Сертификат 68b80077c4e4910a34edbd24145d5c7
Владимир Зубов Юрий Сергеевич
Действителен с 20.01.2022 по 26.03.2023

Ю.С. Зубов

Приложение Б

Акты внедрения

УТВЕРЖДАЮ
 ООО «Иновационные Технологии»
 (Правительство Республики Татарстан)
 Директор
 Коротченко А.Н.
 «12» сентября 2023 г.




АКТ
внедрения результатов диссертационной работы
Давуди Шадфара

Комиссия в составе председателя: директора ООО «Иновационные Технологии» Коротченко А.Н., членов комиссии:

- главного инженера Гарифуллина Р.М.,
- эксперта Новоселова О.А.

Составили настоящий акт о том, что результаты диссертационной работы Давуди Ш. «Гибридная интеллектуальная система для оперативного определения свойств бурового раствора на основе машинного обучения», представленной на соискание ученой степени кандидата технических наук, внедрены в деятельность ООО «Иновационные Технологии». В частности, разработанные автором модели для определения водоотдачи, пластической вязкости и динамического напряжения сдвига были протестированы на данных ранее пробуренных скважин с использованием фактических замеров трех входных параметров (плотность, условная вязкость и содержание твердой фазы раствора), взятых из суточных сводок по буровым растворам. Данные модели машинного обучения показали высокую точность прогноза по всем целевым параметрам ($R^2 \sim 90-92\%$), что дает основание на повышение точности и оперативности мониторинга данных важнейших свойств бурового раствора непосредственно при бурении скважин в режиме реального времени. На основании успешной проверки моделей на реальных данных компании ООО «Иновационные Технологии» запланировано применение разработанных Давуди Ш. моделей во второй половине 2023 года.

Председатель комиссии

 Коротченко А.Н.

Члены комиссии

 Гарифуллин Р.М.
 Новоселов О.А.

**TOMSK
POLYTECHNIC
UNIVERSITY**



**ТОМСКИЙ
ПОЛИТЕХНИЧЕСКИЙ
УНИВЕРСИТЕТ**

Ministry of Science and Higher Education of the Russian Federation
Federal State Autonomous Educational Institution of Higher Education
«National Research Tomsk Polytechnic University» (TPU)
30, Lenin ave., Tomsk, 634050, Russia
Tel. +7-3822-606333, +7-3822-701779,
Fax +7-3822-606444, e-mail: tpu@tpu.ru, tpu.ru
ОКРО (National Classification of Enterprises and Organizations): 02060303,
Company Number: 027000890168,
VAT/KPP (Code of Reason for Registration):
7018007264/701701001, BIC: 016902004

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное
учреждение высшего образования
«Национальный исследовательский
Томский политехнический университет» (ТПУ)
Ленина, пр., д. 30, г. Томск, 634050, Россия
тел. +7-3822-606333, +7-3822-701779,
факс +7-3822-606444, e-mail: tpu@tpu.ru, tpu.ru
ОКПО 02060303, ОГРН 1027000890168,
ИНН/КПП 7018007264/701701001, БИК 016902004

АКТ

внедрения в учебный процесс результатов диссертационной работы Давуди Шадфара

Комиссия в составе:

Боев А.С., к.х.н., директор ИШПР ТПУ, председатель комиссии;
Рукавишников В.С., PhD, директор ЦППС НД ИШПР ТПУ, руководитель
ООП «Технология строительства нефтяных и газовых скважин»;
Чернова О.С., д.г.-м.н., профессор ОНД ИШПР ТПУ;
Матвеев И.В., к.ф.-м.н., доцент ОНД ИШПР ТПУ

составила настоящий акт о нижеследующем,

Результаты диссертационной работы Давуди Ш. «Гибридная интеллектуальная система для оперативного определения свойств бурового раствора на основе машинного обучения», представленной на соискание ученой степени кандидата технических наук, используются в учебном процессе в Инженерной школе природных ресурсов ТПУ в дисциплине «Буровые промывочные жидкости» ООП «Технология строительства нефтяных и газовых скважин».

Студенты ОНД ИШПР ТПУ имеют возможность ознакомиться с результатами диссертационного исследования в ходе выполнения групповых проектов и дипломных работ. Изучение предложенного автором подхода позволяет студентам сформировать навыки разработки гибридных моделей машинного обучения для решения задач регрессионного анализа, таких как прогнозирование свойств бурового раствора и других параметров, например, коллекторских и геомеханических свойств.

Кроме того, материалы диссертационного исследования Давуди Ш. используются в научно-исследовательских работах студентов и аспирантов в Инженерной школе природных ресурсов ТПУ.

Настоящий акт составлен в 3 (три) экземплярах.

Боев А.С.
к.х.н., директор ИШПР ТПУ,
председатель комиссии

 « 16 » « 06 » 2023 г.

Рукавишников В.С.
PhD, директор ЦППС НД ИШПР ТПУ,
руководитель ООП «Технология
строительства нефтяных и газовых
скважин».

 « 16 » « 06 » 2023 г.

Чернова О.С.,
д.г.-м.н., профессор ОНД ИШПР ТПУ

 « 16 » « 06 » 2023 г.

Матвеев И.В.
к.ф.-м.н., доцент ОНД ИШПР ТПУ

 « 16 » « 06 » 2023 г.