

Министерство образования и науки Российской Федерации
федеральное государственное автономное образовательное учреждение
высшего образования
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

Институт Природных ресурсов
Направление подготовки 21.04.01 Нефтегазовое дело
Кафедра Геологии и разработки нефтяных месторождений

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

Тема диссертации
Оценка факторов риска возникновения аварийных ситуаций при сопровождении эксплуатационного бурения (на примере Новопортовского нефтегазоконденсатного месторождения, Западная Сибирь)

УДК 622.243:622.248(571.121)

Студент

Группа	ФИО	Подпись	Дата
2ТМ51	Григорьев Алексей Сергеевич		

Руководитель

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Зав. кафедрой ГРHM	Чернова О.С.	К.Г.-М.Н., ДОЦЕНТ		

КОНСУЛЬТАНТЫ:

По разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
профессор	Белозеров В.Б.	Д.Г.-М.Н		

По разделу «Социальная ответственность»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
доцент	Мищенко М.В.	К.Г.-М.Н.		

ДОПУСТИТЬ К ЗАЩИТЕ:

Зав. кафедрой	ФИО	Ученая степень, звание	Подпись	Дата
ГРHM	Чернова О. С.	К.Г.-М.Н., ДОЦЕНТ		

ПЛАНИРУЕМЫЕ РЕЗУЛЬТАТЫ ОБУЧЕНИЯ ПО ООП

Код	Результаты обучения
1	2
P1	Способность использовать естественнонаучные, математические, экономические, юридические и инженерные знания в области геологии, разработки и эксплуатации нефтяных и газовых месторождений
P2	Способность определять, формулировать и решать междисциплинарные инженерные задачи в области нефтегазовых технологий с использованием профессиональных знаний и современных методов исследования
P3	Способность планировать и проводить исследования в сложных и неопределённых условиях с использованием современных технологий, а также критически оценивать полученные данные
P4	Способность анализировать нестандартные ситуации и быстро выбирать оптимальные решения при разработке нефтяных и газовых месторождений
P5	Способность использовать творческий подход для разработки новых идей и методов проектирования объектов нефтегазового комплекса, а также модернизировать и совершенствовать применяемые технологии нефтегазового производства
P6	Способность разрабатывать многовариантные схемы для достижения поставленных производственных целей, с эффективным использованием имеющихся технических средств
P7	Способность анализировать и систематизировать современные технологические и научные достижения нефтегазовой отрасли, а также выявлять их актуальные проблемы
P8	Способность эффективно работать индивидуально и в качестве члена команды, а также руководить командой, формировать задания, распределять обязанности и нести ответственность за результаты работы
P9	Способность самостоятельно учиться и непрерывно повышать квалификацию в своей профессиональной деятельности
P10	Владеть иностранным языком как средством профессионального общения, на уровне, позволяющем работать в интернациональной среде

Министерство образования и науки Российской Федерации
федеральное государственное автономное образовательное учреждение
высшего образования
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

Институт Природных ресурсов
Направление подготовки 21.04.01 Нефтегазовое дело
Кафедра Геологии и разработки нефтяных месторождений

УТВЕРЖДАЮ:
Зав. кафедрой

(Подпись) _____ (Дата) Чернова О.С.
(Ф.И.О.)

ЗАДАНИЕ
на выполнение выпускной квалификационной работы

В форме:

Магистерской диссертации

(бакалаврской работы, дипломного проекта/работы, магистерской диссертации)

Студенту:

Группа	ФИО
2ТМ51	Григорьев Алексей Сергеевич

Тема работы:

Оценка факторов риска возникновения аварийных ситуаций при сопровождении эксплуатационного бурения (на примере Новопортовского нефтегазоконденсатного месторождения, Западная Сибирь)	
Утверждена приказом директора (дата, номер)	24.07.2017, 6174/С

Срок сдачи студентом выполненной работы:

--	--

ТЕХНИЧЕСКОЕ ЗАДАНИЕ:

Исходные данные к работе <i>(наименование объекта исследования или проектирования; производительность или нагрузка; режим работы (непрерывный, периодический, циклический и т. д.); вид сырья или материал изделия; требования к продукту, изделию или процессу; особые требования к особенностям функционирования (эксплуатации) объекта или изделия в плане безопасности эксплуатации, влияния на окружающую среду, энергозатратам; экономический анализ и т. д.).</i>	Параметры бурения по скважинам месторождения Х. Отчеты бурения. Информация из технической литературы и статей.
---	---

Перечень подлежащих исследованию, проектированию и разработке вопросов <i>(аналитический обзор по литературным источникам с целью выяснения достижений мировой науки техники в рассматриваемой области; постановка задачи исследования, проектирования, конструирования; содержание процедуры исследования, проектирования, конструирования; обсуждение результатов выполненной работы; наименование дополнительных разделов, подлежащих разработке; заключение по работе).</i>	1. Сведения о месторождении 2. Литературный обзор применения методов машинного обучения в бурении 3. Обзор существующих осложнений на скважинах. 4. Финансовый менеджмент, ресурсоэффективность и ресурсосбережение 5. Социальная ответственность 6. Заключение
Перечень графического материала <i>(с точным указанием обязательных чертежей)</i>	1. Стратиграфический разрез месторождения X 2. Карта по отражающему горизонту T₄ месторождения X 3. Схема нейронной сети 4. Типичные осложнения при бурении 5. Классификация осложнений 6. Затраты нефтегазовых компаний на бурение скважин, млрд \$ 7. Распределение времени работы при бурении скважин на месторождении X 8. Распределение непроизводительного времени при бурении скважин на месторождении X 9. Рейтинг параметров бурения 10. Скважина 1. Потеря устойчивости ствола скважины 11. Скважина 2. Потеря циркуляции 12. Скважина 3. Потеря циркуляции 13. Логистическая регрессия 14. Схема дерева принятия решения 15. Разделение классов прямой линией 16. Определение опорных векторов 17. Опорные вектора 18. Схема нейронной сети 19. Метрики precision и recall 20. Чистый дисконтированный денежный поток по годам 21. Пример реализации градиентного бустинга 22. Diagram of the neural network 23. The precision and recall metric
Консультанты по разделам выпускной квалификационной работы <i>(с указанием разделов)</i>	
Раздел	Консультант
Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	Профессор, д.г.-м.н. Белозеров В. Б.
Социальная ответственность	Доцент, к.г.-м.н., Мищенко М. В.

Названия разделов, которые должны быть написаны на русском и иностранном языках:
8 Определение алгоритма с высокой точностью классификации аварий
3 Существующий опыт применения искусственного интеллекта в бурении

Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику	
---	--

Задание выдал руководитель:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Зав. кафедрой ГРНМ	Чернова О. С.	К.Г.-М.Н., доцент		26.06.2017

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
2ТМ51	Григорьев А. О.		26.06.2017

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И
РЕСУРСОСБЕРЕЖЕНИЕ»**

Студенту:

Группа	ФИО
2ТМ51	Григорьев Алексей Сергеевич

Институт	Природных ресурсов	Кафедра	ПОНК
Уровень образования	магистратура	Направление/специальность	21.04.01. нефтегазовое дело

Исходные данные к разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:

1. Стоимость ресурсов научного исследования (НИ): материально-технических, энергетических, финансовых, информационных и человеческих	Расчет сметной стоимости выполняемых работ, согласно применяемой техники и технологии
2. Нормы и нормативы расходования ресурсов	Нормы времени на выполнение определенных видов геоэкологических работ, тарифные ставки заработной платы рабочих, нормы амортизационных отчислений, нормы расхода материалов, инструмента
3. Используемая система налогообложения, ставки налогов, отчислений, дисконтирования и кредитования	Страховые взносы 30% Налог на добавленную стоимость 18%

Перечень вопросов, подлежащих исследованию, проектированию и разработке:

1. Оценка коммерческого и инновационного потенциала НТИ	Технико-экономическое обоснование продолжительности работ по проекту
2. Планирование процесса управления НТИ: структура и график проведения, бюджет, риски и организация закупок	Расчет капитальных вложений и эксплуатационных работ Налоговые отчисления недропользователем
3. Определение ресурсной, финансовой, экономической эффективности	Обоснование эффективности инвестиционного проекта

Перечень графического материала (с точным указанием обязательных чертежей):

1. Чистый дисконтированный денежный поток по годам

Дата выдачи задания для раздела по линейному графику

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор	Белозеров В.Б.	д.г.-м.н.		26.06.2017

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
2ТМ51	Григорьев Алексей Сергеевич		26.06.2017

ЗАДАНИЕ ДЛЯ РАЗДЕЛА «СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»

Студенту:

Группа	ФИО
2ТМ51	Григорьев Алексей Сергеевич

Институт	Природных ресурсов	Кафедра	ПОНК
Уровень образования	магистратура	Направление/специальность	21.04.01.Нефтегазовое дело

Исходные данные к разделу «Социальная ответственность»:

1. Описание рабочего места (рабочей зоны, технологического процесса, механического оборудования) на предмет возникновения: – вредных проявлений факторов производственной среды (метеоусловия, вредные вещества, освещение, шумы, вибрации, электромагнитные поля, ионизирующие излучения) – опасных проявлений факторов производственной среды (механической природы, термического характера, электрической, пожарной и взрывной природы) – негативного воздействия на окружающую природную среду (атмосферу, гидросферу, литосферу) – чрезвычайных ситуаций (техногенного, стихийного, экологического и социального характера)	Рассмотрены факторы, которые влияют на окружающую среду при бурении скважин. Меры контроля и предупреждения возникновения чрезвычайных ситуаций.
2. Знакомство и отбор законодательных и нормативных документов по теме	

Перечень вопросов, подлежащих исследованию, проектированию и разработке:

1. Анализ выявленных вредных факторов проектируемой производственной среды в следующей последовательности: – физико-химическая природа вредности, её связь с разрабатываемой темой; – действие фактора на организм человека; – приведение допустимых норм с необходимой размерностью (со ссылкой на соответствующий нормативно-технический документ); – предлагаемые средства защиты (сначала коллективной защиты, затем – индивидуальные защитные средства)	Отклонение температуры может негативно влиять на здоровье и самочувствие работников на буровой. Недостаток освещенности может способствовать увеличению нагрузки на глаза.
2. Анализ выявленных опасных факторов проектируемой произведённой среды в следующей последовательности – механические опасности (источники, средства защиты); – термические опасности (источники, средства защиты); – электробезопасность (в т.ч. статическое электричество, молниезащита – источники, средства защиты); – пожаровзрывобезопасность (причины, профилактические мероприятия, первичные средства пожаротушения)	Рассмотрены вредные факторы такие как: уровень шума, освещенность рабочей зоны и электромагнитное излучение. А также изучены опасные факторы: электрический ток, пожарная и взрывная опасность.
3. Охрана окружающей среды: – защита селитебной зоны – анализ воздействия объекта на атмосферу (выбросы); – анализ воздействия объекта на гидросферу (сбросы);	Буровая потенциально может нести в себе большую угрозу окружающей среде. НГВП, мусор на участке – все

– анализ воздействия объекта на литосферу (отходы); – разработать решения по обеспечению экологической безопасности со ссылками на НТД по охране окружающей среды.	это должно контролироваться во избежание загрязнения окружающей среды.
4. Защита в чрезвычайных ситуациях: – перечень возможных ЧС на объекте; – выбор наиболее типичной ЧС; – разработка превентивных мер по предупреждению ЧС; – разработка мер по повышению устойчивости объекта к данной ЧС; – разработка действий в результате возникшей ЧС и мер по ликвидации её последствий	Возможные ЧС на объекте: техногенного характера - производственные аварии и пожары; природного характера – сильный мороз, сильный снегопад, лесные пожары; биолого-социального характера – вспышки инфекционных заболеваний; экологического характера – разрушение озонового слоя, превышение ПДК вредных примесей в атмосфере.
5. Правовые и организационные вопросы обеспечения безопасности: – специальные (характерные для проектируемой рабочей зоны) правовые нормы трудового законодательства; – организационные мероприятия при компоновке рабочей зоны	Рабочее место должно соответствовать требованиям ГОСТ 12.2.032-78.
Перечень графического материала:	
При необходимости представить эскизные графические материалы к расчётному заданию (обязательно для специалистов и магистров)	

Дата выдачи задания для раздела по линейному графику	
---	--

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Мищенко М.В.	к.г. -м.н.		26.06.2017

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
2ТМ51	Григорьев Алексей Сергеевич		26.06.2017

РЕФЕРАТ

Выпускная квалификационная работа содержит 93 страницы, 23 рисунка, 14 таблиц, 40 источников, 2 приложения.

Ключевые слова: ОСЛОЖНЕНИЯ ПРИ БУРЕНИИ, МАШИННОЕ ОБУЧЕНИЕ, НЕЙРОННАЯ СЕТЬ, ПОВЫШЕНИЕ ЭФФЕКТИВНОСТИ, ГРАДИЕНТНЫЙ БУСТИНГ, КЛАССИФИКАЦИЯ

Объектом исследования являются скважины с осложнениями в процессе бурения.

Цель работы – создание обучающегося алгоритма который на основе накопленных исторических данных о ранее пробуренных скважинах будет классифицировать аварийные ситуации при сопровождении бурения.

В процессе исследования проводились работы по изучению методов машинного обучения; обзору существующих практик применения данных моделей для повышения эффективности бурения. Проанализированы предоставленные отчеты по бурению скважин на месторождении. Выявлены скважины в которых встречались осложнения. Проведены расчеты на различных алгоритмах машинного обучения для выявления алгоритма, дающего минимальный процент ошибки.

В результате исследования рассчитана модель на основе градиентного бустинга для классификации осложнений в процессе бурения.

Область применения: бурение нефтяных и газовых скважин.

Экономическая эффективность/значимость работы заключается в способности построенной модели классифицировать осложнения в процессе бурения, что позволяет буровой команде заблаговременно устранять возникающие осложнения.

ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ

ИД – индекс доходности;

ИН – искусственный интеллект;

КРС – капитальный ремонт скважины;

ММП – многолетнемерзлые почвы;

НН – нейронная сеть;

НГКМ – нефтегазоконденсатное месторождение;

НДПИ – налог на добычу полезных ископаемых;

ПИД - пропорционально-интегрально-дифференцирующий регулятор;

РИ – роевой интеллект;

РУС – роторная управляемая система;

СЗЗ – санитарно-защитная зона;

УВ – углеводороды;

ЧДД – чистый дисконтированный доход.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	13
1. СВЕДЕНИЯ О МЕСТОРОЖДЕНИИ	14
1.1. Общие сведения о месторождении	14
1.2. Стратиграфия месторождения	16
1.3. Тектоническое строение	18
1.4. Нефтегазоносность	18
2. ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В НЕФТЕГАЗОВОЙ ОТРАСЛИ	22
2.1. Интеллектуальные скважины	23
1.5. Машинное обучение	24
2.3. Рассуждения на основе аналогичных случаев	25
2.4. Нечеткая логика	26
2.5. Перерабатывающий сектор	26
3. СУЩЕСТВУЮЩИЙ ОПЫТ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В БУРЕНИИ	28
4. КЛАССИФИКАЦИЯ ОСЛОЖНЕНИЙ ПРИ БУРЕНИИ	34
5. ВЛИЯНИЕ ОСЛОЖНЕНИЙ НА ПАРАМЕТРЫ БУРЕНИЯ	37
5.1. Параметры бурения	37
5.1.2. Частота вращения в минуту	37
5.1.2. Параметры насоса	38
5.1.3. Наклонение – азимут	38
5.1.4. Нагрузка на долото	38
5.1.5. Механическая скорость проходки	39
5.1.6. Свойства бурового раствора	39
5.1.7. Крутящий момент	39
5.1.8. Каротаж во время бурения	40
5.2. Признаки осложнений в процессе бурения	40
6. ИСХОДНЫЕ ДАННЫЕ ДЛЯ СОЗДАНИЯ МОДЕЛИ	43
7. ИСПОЛЬЗУЕМЫЕ АЛГОРИТМЫ ДЛЯ СОЗДАНИЯ МОДЕЛИ	50
7.1. Логистическая регрессия	50
7.2. Наивный байесовский классификатор	51
7.3. Метод k-ближайших соседей	52
7.4. Дерево принятия решений	53
7.5. Метод опорных векторов	54
7.6. «Случайный лес»	56
7.7. Градиентный бустинг	57
7.8. Нейронная сеть	58

8. ВЫБОР АЛГОРИТМА С ВЫСОКОЙ ТОЧНОСТЬЮ КЛАССИФИКАЦИИ АВАРИЙ.	60
9. ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ	65
10. СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ	71
10.1. Освещенность.....	71
10.2. Шум и вибрация.....	73
10.3. Источники опасности для персонала на буровой.....	75
10.4. Энергобезопасность.....	76
10.5 Требования по охране труда для рабочих при бурении скважин	77
ЗАКЛЮЧЕНИЕ.....	81
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ.....	82
ПРИЛОЖЕНИЕ А	86
ПРИЛОЖЕНИЕ В. Пример реализации градиентного бустинга.....	96

ВВЕДЕНИЕ

Основной задачей нефтегазовых компаний на сегодняшний день является разработка новых и перспективных месторождений, увеличение добычи со зрелых месторождений, а также разработка и внедрение новых технологий для сокращения затрат, связанных с бурением и добычей скважинной продукции. Затраты компаний на бурение скважин являются одними из больших. Ежегодно на бурение компаниями тратятся десятки миллиардов долларов. Около 15% от этой суммы уходит на затраты, связанные с ликвидацией осложнений в процессе бурения. Иногда непродуктивное время простоя скважины из-за возникшего осложнения может быть равно продуктивному времени работы буровой бригады, т.е. 50% от суммарного времени работы буровой.

Стоит отметить, что за последние 20 лет внедрено множество технологий, которые позволили улучшить процесс бурения (каротаж повышенного разрешения во время бурения, автоматизированные пульта бурильщика, роторные управляемые системы).

Тем не менее, проблема своевременного прогнозирования и классификации проблем, которые возникают в процессе строительства скважины остается актуальной. Необходимо создание новой методологии, которая должна помочь персоналу буровой своевременно принимать решения о возможных проблемах в процессе бурения на основе анализа данных в реальном времени, что повысит эффективность работы и соответственно снизит затраты на бурение.

Целью данной работы является создание обучающегося алгоритма который на основе накопленных исторических данных о ранее пробуренных скважинах будет предсказывать аварийные ситуации при сопровождении бурения. Такая система поддержки принятия решений поможет инженеру вовремя вмешаться в процесс бурения и предотвратить высокие расходы на простой и ремонт оборудования, вследствие аварии.

1. СВЕДЕНИЯ О МЕСТОРОЖДЕНИИ

1.1. Общие сведения о месторождении

Нефтегазоконденсатное месторождение X - расположено в Юго-Восточной части полуострова Ямал в 250 км к Северу от г. Надым, в 30 км от побережья Обской губы Ямало-Ненецкого автономного округа Российской Федерации и относится к Западно-Сибирской нефтегазоносной провинции.

Месторождение X было открыто в 1964 году, запущено в опытно-промышленную эксплуатацию в 2009 году. Является одним из самых крупных разрабатываемых месторождений в ЯНАО. Извлекаемые запасы месторождения по категории C1 и C2 — более 250 млн тонн нефти и конденсата, а также более 320 млрд кубометров газа (с учетом палеозойских отложений) [25, 26].

В качестве основных особенностей месторождения можно выделить:

1. Месторождение X характеризуется самым большим на севере стратиграфическим этажом продуктивности. Газовые, газоконденсатные, нефтегазоконденсатные, вероятно, нефтяные и газонефтяные залежи установлены в интервале от кровли сеномана до базальных горизонтов юры.

2. Особенностью месторождения является крайне малая газоносность разрезов юры и нижнего мела-сеномана: во всех смешанных скоплениях геологические запасы нефти существенно превышают запасы свободного газа, за исключением залежи, приуроченной к пласту НП-1, а высокоструктурная ловушка по кровле сеномана, сопоставимая с ловушками Бованенковского и Харасавэйского месторождений, содержит незначительное скопление газа. Промышленные скопления нефти выявлены в средней части разреза осадочного чехла и приурочены к верхним горизонтам средней юры, новопортовской толще и верхам апта. Высока вероятность того, что считающиеся едиными залежи в юрских и валанжинских горизонтах месторождения расчленяются разломами на целый ряд тектонически-экранированных и комбинированных залежей, о чем

свидетельствуют данные испытания большого числа скважин. Кроме того, нигде на Ямале нефть не забирается стратиграфически так высоко, как на месторождении X. Выше нефтегазовой залежи горизонта ТП₁ зафиксированы обильные нефтепроявления — полупромышленные притоки тяжелой нефти, аналогичной аптской, в альбских горизонтах, что совершенно не характерно для ЯГНО, но часто наблюдается в средних и верхних горизонтах покурской свиты НПТР выше границы начала ФМГБ на структурах, интенсивно нарушенных высокоамплитудными разломами.

Обращает на себя несоответствие уровня катагенетической преобразованности ОВ пород в кровле юры и новопортовской толщи уровню геохимической зрелости нефтей в горизонте Ю₂₋₃ и особенно НП₁—НП₁₀.

В частности, «континентальные» по своим геохимическим характеристикам нефти тюменской свиты и тем более новопортовской толщи дельтового генезиса демонстрируют высокую геохимическую зрелость, в отличие от аптской незрелой нефти, в то время как уровень катагенетической преобразованности нефтематеринских (потенциально) вмещающих продуктивные горизонты глин не выходит за пределы градаций ПК₃³—МК₁¹ (R° — 0,45—0,52 %) и явно недостаточен для масштабной битумо(нефте)генерации в существенно гумусовом ОВ, что прямо свидетельствует об относительно больших расстояниях вторичной миграции в латеральном направлении с юго-востока на северо-запад и отчасти, ремиграции (по разломам), тем более, что в пределах НП наблюдается наименьшая толщина региональной покрывки (вертикальное расстояние от подошвы самого нижнего горизонта группы НП до кровли горизонта Ю₂ — 50—30, местами до 20 м).

Рассматривая нефтеносность зоны X, отметим следующее. Примечательна близость (по сути — тождественность) физикохимических свойств и состава новопортовских и тюменских нефтей НМ, несмотря на значительные отличия фациальных характеристик предположительно материнских пород новопортовской толщи, верхней и особенно средней юры

(тюменской свиты). Попадание новопортовских нефтей в горизонты Ю2-3 маловероятно по ряду причин, обратное — значительно более вероятное событие... При этом нефти соседнего Ростовцевского НГКМ разительно отличаются от нефтей НМ низкой плотностью и парафинистостью и малым содержанием смол и особенно асфальтенов: по своему геохимическому облику они весьма близки газоконденсатам других месторождений Ямала.

3. Необычность, аномальность месторождения X для арктических районов Западной Сибири, кроме всего прочего, выражается в водоносности всех горизонтов регионально газоносной таноппинской свиты (кроме горизонта ТП₁), что не характерно для Ямала и Гыдана. Кроме того, в объеме НМ наблюдается минимальная напряженность как геотермического, так и флюидобарического полей, и признаки ВГПД начинаются только в низах юры на дальних восточных склонах вала, хотя в пределах Ростовцевского и Хамбате́йского месторождений ВГПД начинаются уже в низах мела (в НП и АТ) [27].

1.2 Стратиграфия месторождения

Стратиграфический разрез территории севера Западно-Сибирской плиты сложен меловыми, палеогеновыми и неогеновыми отложениями.

В геологическом строении НГКМ X принимают участие породы доюрского складчатого фундамента и осадочные образования — представленные терригенными породами юрского, мелового, палеогенового и четвертичного возраста (рис. 1) [2]. Максимальная толщина разреза месторождения вскрыта скв.130 и составляет 2855 м.

Система		Колонка		Индекс		Описание
Отдел	Сыта (подсыта)			Индекс	Мощ., м	
Палеогеновая	Четвертичный			Q	30-150	Чередуются супинки, супеси, глины, пески, алевролиты, часто содержащие рассеянные включения, прослои и линзы кристаллических пород складчатого обрамления плиты и подстилающих пород мезозоя и палеогена.
		Тибейская		P ₁	до 100	Глины опоквидные, опоки, диатомиты с прослоями песчаных пород.
Меловая	Верхний	Ганьминская			до 220	Серые и зеленовато-серые алевролитистые глины, часто известковые, с прослоями глинистых мергелей, с обугленным растительным детритом и пирилизированными остатками водорослей.
		Березовская	Верх.	K ₂	200-240	Серые и зеленовато-серые, слабо алевролитистые глины, опоквые лишь в подошве подсыты.
		Нижн.				Темно-сер. с зеленовато-голуб. оттенком опоки и опоквидные глины с прослоями глинистых алевролитов и мелкозернистых песчаников. В кровле - пласт органогенных силицитов.
		Кузнецовская			до 55	Серые, темно-серые и реже бурые глины, иногда известковые, в основании прослой глинистых алевролитов с глауконитом.
		Марресская			355-445	Сероватые алевролиты, уплотненные пески и известковые песчанники с линзовидными прослоями и нелетучими пластинами серых буровато-серых алевролитистых глин.
	Нижний	Яронская		K ₁	62-160	Глины темно-серые и серые, тонкоотмученные и алевроитовые, участками слабобитуминозные, с пластинами песчанников и алевролитов.
		Танопинская			470-529	Песчаники и алевролиты светло-серые, серые с глинистым, реже карбонатно-глинистым цементом. Глины серые и темно-серые, иногда с буроватым оттенком, углистые, слюдястые.
		Ахская			500-700	Песчаники и алевролиты светло-серого и серого цвета с глинистым и карбонатным цементом, массивные и косо-волнистослойчатые, с включениями мелкого углистого детрита слюд. Глины серые и темно-серые, алевролитистые, слюдястые, иногда с прослойками алевроитового материала, часто карбонатизированные.
		Баженская		J ₃	30-60	Темно-серые до черных аргилитоподобные глины, грубоплитчатые, с землистой поверхностью излома.
	Юрская	Абалаская	Ниж. Ср. Вер.		до 30	Глины темно-серые до серых, тонкоотмученные, однородные. Песчано-алевритовые породы с глинистым цементом. Иногда породы имеют четко выраженный зеленоватый оттенок (глауконит). Темно-серые, серые глины, алевроитовые и тонкоотмученные с фаунистическими остатками.
		Томская			245-335	Глины и аргиллиты темно-серые и серые с буроватым оттенком, в разной степени алевроитистые, слюдястые, плотные. Встречаются прослой черной углистой глины и углей. Песчаники и алевролиты серые мелко- и среднезернистые, плотные, крепкие с глинисто-карбонатным цементом, иногда сидеритизированы. В кровельной части песчаники выветрелые, каолинитизированные.
		Лайдинская			35-100	Темно-серые, реже буровато-серые глины с редкими прослоями серого и светло-серого песчано-алевритового материала. Иногда в низах свиты встречаются прослой гравелитов.
		Джангодская		J ₁₋₂	100-190	Песчаники и алевролиты мелкозернистые, редко среднезернистые, светло-серые и зеленовато-серые с включениями обугленного растительного детрита, иногда тонких линзочек угля. В песчаниках встречаются прослой (до 5 см) гравелитов, в составе которых присутствуют гальки кварца, кремнистых пород и окатыши аргилитов.
		Ливинская			2-17	Сероватые глины с маломощными прослоями серых и светло-серых песчанников и алевролитов.

Рисунок 1 – Стратиграфический разрез месторождения X [2]

1.3 Тектоническое строение

По данным сейсморазведочных работ на месторождении установлены тектонические нарушения субмеридиального и северо-западного простирания. Все они прослежены фрагментарно (рис. 2). Амплитуды их в разрезе различные и соизмеримы с толщинами глинистых экранов. Простирание нарушений по результатам одних и тех же сейсмических исследований интерпретируется по-разному, поэтому их достоверность в интервале продуктивных толщ (новопортовская, тюменская свита) вызывает определенное сомнение. Наличие предполагаемых тектонических нарушений подтверждается и данными бурения. Однако протрассировать их по площади пока не представляется возможным [28].

1.4 Нефтегазоносность

В разрезе месторождения установлена нефтегазоносность в интервале глубин 470-3000 м от сеномана до палеозоя. Нефтегазоносными являются 19 пластов месторождения. Наибольшее количество залежей установлено в пределах южной периклинали и южного купола. Далее в северном направлении новопортовская толща выклинивается и количество залежей уменьшается. (табл. 1, 2) Ниже приведены основные геолого-геофизические характеристики объекта Ю₂₋₆ [29].




Рисунок 2 - Карта по отражающему горизонту T_4 месторождения X: 1 – номер скважина/абсолютная отметка кровли пласта; 2 – изогипсы, м; 3 – тектонические нарушения

Таблица 1 – Характеристики объекта Ю₂₋₆

Средняя толщина, м:	
газонасыщенная	15,4
нефтенасыщенная	16,3
Коэффициент пористости	0,18
Проницаемость, 10^{-3} мкм ²	12,6
Коэффициент песчанистости	0,31
Расчлененность	35,9
Вязкость нефти, мПа·с, в условиях:	
пластовых	0,82
поверхностных	8,2
Газовый фактор, м ³ /т	110

Таблица 2 - Характеристика нефтегазоносности месторождения X

Индекс пласта	Тип залежи	Интервал залегания а.о., м	ГВК, ГНК, ВНК, а.о., м	Длина, км	Ширина, км	Высота, м	Дебиты, тыс. м³/сут. м³/сут	Содержание стабильного конденсата, г/м³	Пластовое давление, МПа	Пластовая температура, °С
ПК ₁	Газовая	412–435	435	17,5	7,8	23	64,7	—	4,36	Не замер.
ХМ ₁	Газовая	832–855	850–855	13,0	7,0	23	24,0–181,0	—	8,84	+25,2
ТП ₁	Газонефтяная	920–950	939, 944–950	16,2	6,5	30	Г–до 194,0 Н–до 21,27	—	9,69	+27
НП ₁ сев.	Газоконденсатная	1754–1819	1819	7,2	4,5	65	Г–до 199,8	44,77	17,9–18,7	+51–+58
НП ₁ южн.	Газоконденсатно-нефтяная	1715–1855	1843, 1855	19,3	14,0	140	Г–до 382,9 Н–до 6,0	44,77	18,27	+56
НП _{2–3}	Газоконденсатно-нефтяная	1757–1882	1825, 1855–1882	33	13	125	Г–24,1–706 Н–3,6–73,5	44,3	17,8–19,4	+53–+60
НП ₄	Газоконденсатно-нефтяная	1766–1870	1820–1840, 1870	24,0	12,0	104	Г–до 348,1 Н–6,0–147,1	55,07	18,15–19,27	+55–+61
НП _{5–6}	Газоконденсатно-нефтяная	1823–1875	1845, 1858–1875	14,2	6,8	52	Г–66,8–264,2 Н–1,6–82,0	52,79	19,2	+55–+62
НП ₇	Газоконденсатно-нефтяная	1846–1870	1858, 1870	9,0	7,0	24	Г–до 65,0 Н–до 30,9	—	19,8	+57–+61
НП ₈ южн.	Газоконденсатно-нефтяная	1869–1894	1882, 1891–1894	7,0	4,8	25	Г–136,6 Н–до 32,4	—	18,7–19,0	+54–+63
НП ₈ сев.	Газоконденсатно-нефтяная	1838–1918	1882, 1918	4,5	4,0	80	Г–до 180,9 Н–до 3,4	—	—	—
НП ₉	Газоконденсатно-нефтяная	1905–1968	1915, 1968	11,0	10,0	63	Г–4,5 Н–39,4	58,89	19,2	+55–+60
НП ₁₀	Газоконденсатно-нефтяная	1893–1983	1936–1941, 1974–1983	8,5	7,0	90	Г–до 237 Н–5,6–43,2	58,89	19,9	+58–+64
НП ₁₁	Газоконденсатно-нефтяная	1947–1982	1953, 1982	3,7	3,90	35	Г–80,84 Н–13,4–14,3	—	Не опр.	Не опр.
НП ₁₂	Газоконденсатная	2017–2055	2041–2055	6,5	2,5	38	10,3	—	Не замер.	Не замер.
Ю _{2–1} сев.	Газоконденсатная	Не опр.	Не опр.	3,5	2,5	Не опр.	19,9	43,4	Не опр.	Не опр.
Ю _{2–1} центр.	Газоконденсатно-нефтяная	1950–2030	1990, 2030	13,5	6,5	80	Г–42,6–117,0 Н–до 5,4	43,4	19,76	+65
Ю _{2–1} перикл.	Нефтяная	1980–2030	2030	3,3	1,6	50	3,6	—	Не опр.	Не опр.
Ю _{2–2} сев.	Газоконденсатная	1910–1990	1990	7,0	5,5	80	19,9	43,4	Не опр.	Не опр.
Ю _{2–2} центр.	Газоконденсатно-нефтяная	1902–2030	1990–2005, 2030	18,0	8,0	128	Г–26,9–150,0 Н–1,8–24,4	—	Не опр.	Не опр.
Ю _{2–2} перикл.	Нефтяная	1973–2038	2038	7,0	6,0	65	2,2–5,0	—	Не опр.	Не опр.
Ю ₃	Газоконденсатно-нефтяная	1914–2065	1980–1990, 2005–2065	23,0	7,5	104–116	Г–до 281,2 Н–3,6–58,2	—	19,76	+65
Ю ₄ сев.	Газоконденсатно-нефтяная	1939–2036	1990–2000, 2030–2036	20,0	6,5	97	Г–30,0–246,6 Н–1,2–158,9	153	Не опр.	Не опр.
Ю ₄ южн.	Нефтяная	1982–2035	2030–2035, 2037,5	7,5	7,5	53	0,9–22,6	—	Не опр.	Не опр.
Ю ₅	Газоконденсатно-нефтяная	1972–2042	2000, 2040–2042	210	6,5	32–68	Г– не опр. Н–0,9	—	Не опр.	Не опр.
Нижнеюрская	Газоконденсатная	2431–2615	2615	10,5	7,7	184	26,7–138,8	—	25,5	+79
Палеозой вост.	Газоконденсатная	2620–2940	2940	11,0	6,5	320	20,7–379,1	43,5	26,93	+77
Палеозой сев.	Газоконденсатная	Не опр.	2500	—	—	—	145,2	435	26,9	+80

2. ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В НЕФТЕГАЗОВОЙ ОТРАСЛИ

Достижения в нейронных сетях и машинном обучении предоставили компьютерам (и машинам) интуицию - способность привести разумный результат в проблемах, которые трудноразрешимы или необоснованно трудны для решения формальными логическими средствами [4]. За последнее десятилетие использование машинного обучения, прогностической аналитики и других технологий на основе искусственного интеллекта в нефтегазовой отрасли значительно возросло. Эти технологии продвинулись в течение последних 3 лет, поскольку падение цен на нефть побудило компании искать инновационные способы повышения эффективности, сокращения затрат и минимизации незапланированных простоев.

Использование передового программного обеспечения для анализа данных и предоставления рекомендаций по повышению эффективности работы не является новым для нефтегазовой отрасли. С начала 1990-х годов операторы в сегменте сбыта используют широкий спектр технологий, предназначенных для сбора и анализа информации, касающейся скважинных условий (например, температуры, давления и геофизического состава), характеристик сверла и динамики коллектора.

Однако на протяжении многих лет внедрение этих инструментов требовало значительных авансовых инвестиций, а это означало, что они могли бы быть финансово оправданы на скважинах с высокими уровнями производства.

За последние несколько лет это изменилось, так как прогресс в области компьютерной техники и программного обеспечения, а также число поставщиков, предлагающих решения, основанные на данных, увеличились. Относительный успех технологии на основе ИИ в других областях, таких как здравоохранение, финансы и производство, также привлек внимание

нефтегазовой промышленности, что побудило многие компании экспериментировать с ней в своей собственной деятельности.

Пожалуй, самым неожиданным драйвером спроса на продвинутые аналитические инструменты стало падение цен на нефть во всем мире, которое ужесточило маржу и вынудило операторов отвлечь внимание от увеличения производства до его оптимизации.

2.1. Интеллектуальные скважины

Беспроводные сети и удаленные датчики, которые могут собирать и передавать данные из различных точек измерения, становятся все более распространенными на нефтяном месторождении. Таким образом, использование передовых программных решений с использованием сложных алгоритмов машинного обучения, которые имеют возможность просеивать терабайты данных для идентификации шаблонов, делать прогнозы и давать рекомендации обслуживающему персоналу относительно оптимального управления и управления их активами.

В операциях с высоким уровнем автоматизации, программное обеспечение полностью обходит людей и делает микронастройки параметрами, такие как частота насоса, скорость проникновения и скорости впрыска химикатов для поддержания оптимального производства и эффективности.

Собранные данные также могут использоваться для отслеживания характеристик оборудования, помогающего предсказывать механические сбои и оповещать операторов о возможных сбоях, поэтому время простоя незапланированного оборудования может быть сведено к минимуму. Поскольку программное обеспечение обрабатывает больше объемы данных, его способность делать прогнозы улучшается, адаптируется и становится

более умным с течением времени методом обучения, подобным человеческому интеллекту.

1.5. Машинное обучение

Приведенные в действие сотнями компьютерных серверов и способные обрабатывать миллиарды входных данных в режиме реального времени, алгоритмы машинного обучения имеют возможность связывать информацию, связанную с несколькими переменными. Это позволяет быстро определить тенденции и закономерности, которые в противном случае были бы трудными и трудоемкими для обнаружения даже для самых подготовленных человеческих глаз.

Например, вместо мониторинга одной переменной, такой как перепад давления в резервуаре, программное обеспечение для машинного обучения может принимать во внимание ряд факторов, важных для общей стратегии бурения. К ним относятся оценки оборудования, сейсмические колебания, проницаемость пластов и термические градиенты. При наложении слоев эти данные могут использоваться для определения не только оптимального направления бурового долота, но и того, как его следует контролировать (то есть скорости проникновения), когда он бурится сквозь землю.

Информация регистрируется, конкретизируется и визуализируется с помощью интерфейсов, что позволяет персоналу контролировать общую производительность скважин и принимать более разумные решения, направленные на улучшение работы.

Предиктивное программное обеспечение также может использоваться для анализа данных, чтобы определить, способствуют ли скважинные условия потенциально катастрофическим событиям, таким как сломанное оборудование, застрявшая труба или выбросы. Используя данные для понимания того, что способствует вероятности такого события, алгоритмы

могут давать рекомендации для системы управления и обслуживающего персонала для минимизации вероятности такого события. Это стало критическим, учитывая тот факт, что стоимость непроизводительного времени в некоторых случаях может достигать миллионов долларов в день.

2.3. Рассуждения на основе аналогичных случаев

Другая технология, которую исследовательские и производственные компании используют наряду с алгоритмами машинного обучения, это технология рассуждения на основе аналогичных случаев (CBR). CBR - это подмножество ИИ, которое работает путем очистки баз данных задокументированных проблемных ситуаций в режиме реального времени, чтобы попытаться идентифицировать случаи, сходные с проблемой, с которой приходится сталкиваться. Когда извлекается случай, который имеет соответствующее описание, система углубляется, чтобы узнать, какие действия были предприняты для решения проблемы.

Системы CBR могут использоваться сами по себе или в сочетании с другими аналитическими решениями. Они стали более распространенными во всем буровом секторе и предоставляют операторам рекомендации о том, как решать различные проблемы, связанные с скважиной. Сама технология может быть эффективным инструментом разработки руководящих принципов лучшей практики и стала полезной помощью для персонала, которому поручено принимать трудные решения. Однако системы на базе CBR ограничены тем, что для их эффективности требуется большая библиотека/база данных с возможностью поиска, а также краткое описание текущих проблемных ситуаций.

2.4. Нечеткая логика

Технология на основе ИИ также оказала влияние на то, как поисково-разведочные компании открывают и моделируют запасы нефти. Передовые технологии обработки изображений продолжают играть самую важную роль в определении местоположения бурения. Однако в большинстве случаев конкретные характеристики давления, объема, температуры и проницаемости резервуара могут быть получены только буровыми или пилотными скважинами.

Нечеткая логика - это метод на основе ИИ, используемый для прогнозирования и рассуждений, когда информация ненадежна и/или неполна. Это делает его особенно полезным для заполнения информационных зазоров во время характеристики резервуара. Он также становится все более распространенным явлением в других приложениях для инженерного контроля в энергетической отрасли, где входные параметры сильно варьируются. Эти виды использования включают улучшенное восстановление, интенсификацию и бурение скважин.

2.5. Перерабатывающий сектор

Использование технологий, связанных с ИИ в нефти и газе, не прекращается при разведке и добыче, так как многие операторы в нефтеперерабатывающем секторе теперь полагаются на интеллектуальную аналитику и модельный прогностический контроль для постоянного улучшения общей производительности своих объектов и более эффективного обслуживания оборудования.

Некоторые компании даже применяют его для упрощения транспортировки, переработки и распределения нефти и газа. Эти фирмы используют передовые алгоритмы для анализа данных, таких как

экономические условия и погодные условия для прогнозирования спроса, что позволяет лучше распределять ресурсы и оптимальные цены.

Несмотря на то, что все большее число нефтегазовых компаний используют технологии на основе ИИ, отрасль в целом по-прежнему отстает от многих других, когда она полностью использует свои данные. Разрушение информационных силосов и предоставление данных более доступным для ключевых лиц, принимающих решения по различным дисциплинам, будут неотъемлемой частью улучшения этой ситуации в ближайшие годы.

Однако в краткосрочной перспективе использование машинного обучения, предсказательной аналитики и других решений, основанных на данных, будет по-прежнему помогать компаниям повышать эффективность и оставаться прибыльным в нынешних экономических условиях [30].

3. СУЩЕСТВУЮЩИЙ ОПЫТ ПРИМЕНЕНИЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В БУРЕНИИ

Потребности практики бурения глубоких нефтяных и газовых скважин предъявляют к теории широкий круг требований. При этом теория должна объяснить течение технологических процессов бурения как в нормальных условиях, так и в момент возникновения осложнений, и во время развития, рассматривая осложнения как составную часть таких процессов. Желательно, чтобы теоритическое описание осложнений позволяло судить о них не только на качественном уровне, но и оценить количественно взаимосвязь их существенных переменных. Из-за довольно узкого прикладного характера задач моделирования и предупреждения осложнений их постановка и оценка полученных результатов должны прежде всего ориентироваться на потребности и возможности практики. Существующие возможности вычислительной техники позволяют осуществить вычисления, которые несколько лет назад казались трудоемкими.

Рассмотрим кратко существующие труды, которые были направлены на улучшение процесса бурения с использованием нейронных сетей и машинного обучения.

Шен Чжан и др. [5] в своей работе использовали непараметрическую систему нечетких выводов для прогнозирования состояния роторной управляемой системы. Этот метод позволяет постоянно обновлять прогноз состояния РУС на основе параметров бурения и условий эксплуатации в режиме реального времени. Это позволяет снизить затраты на ремонт и техническое обслуживание бурового оборудования.

Янфанг Ванг [6] представил подход, использующий методы нейронного программирования, такого как многослойное нейронное сетевое моделирование для прогнозирования нелинейных задач оптимизации бурения. Предложенная им модель может не только предсказывать давление

насоса, в качестве искомого параметра, но также может обеспечить воздействие каждого входного параметра в данной модели.

Механизм разрушения механической системы обычно сопровождается несколькими последовательными происшествиями на пути к потере работоспособности. Поэтому отслеживание состояние работоспособности механизма, даже если машина работает исправно, очень важно для обнаружения, идентификации и локализации неисправности (т.е. диагностики) и оценки оставшегося срока полезного использования компонента/машины. Так Фатих Камчи и другие [7] с помощью скрытой Марковской модели дают возможность оценить состояние работоспособности механизма с помощью наблюдаемых сигналов с датчиков. В частности, данная модель использовалась для оценки состояния буровых долот.

В настоящее время широкое применение получили методы программирования нейронных сетей для решения проблем в различных сферах. Искусственная нейронная сеть представляет собой взаимосвязанную группу узлов, аналогичную нашей мозговой сети. На рисунке 3 представлена схема нейронной сети. Здесь имеется три слоя, каждый круг представляет собой нейрон, а линия представляет собой соединение между нейронами.




Рисунок 3 - Схема нейронной сети [31]

Первый слой имеет входные нейроны, которые отправляют данные через линии связи во второй слой нейронов, а затем через большое количество связующих узлов к третьему слою выходных нейронов [31].

Например, Линд Ю. Б. и Кабирова А. Р. [8] использовали нейронную сеть для прогнозирования вероятных проблем, которые могут возникнуть при бурении скважин на основе информации о запасах нефтяного месторождения. Результаты вычислительных экспериментов показали эффективность разработанного программного обеспечения.

Байесовскую нейронную сеть использовал в своей работе Абдаллы Салеха Х. Альями [9]. По результатам работы была разработана экспертная система для бурения, которая может использоваться в качестве обучения для молодых инженеров или в качестве системы консультаций при различных этапах проектирования буровых работ. Байесовская модель использовалась для разработки моделей заканчивания скважин, выбора буровых растворов, контроля процесса бурения и цементирования скважин, а также работ при высоком давлении.

Инженеры-исследователи в области буровых работ всегда ищут методы прогнозирования неожиданных ситуаций в процессе бурения и соответствующее улучшение связанных с этим параметров. Прогнозированию скорости бурения уделяется большое внимание из-за его влияния на оптимизацию различных параметров, что непосредственно приводит к снижению издержек. Джаханбахши Р. и Кешаварзи Р. использовали нейронную сеть для прогнозирования скорости бурения [10]. В качестве входных параметров участвовали такие параметры как тип породы, механические свойства пласта, гидравлика, тип долота и его свойства, скорость вращения ротора так как они считаются наиболее важными для прогнозирования скорости проходки. Мехран Моназами и другие [11] в своей статье так же используют нейронную сеть для оценки скорости бурения. Данный метод рассматривается авторами как наиболее эффективный инструмент в прогнозировании по сравнению с имеющимися в настоящее время процедурами. Модель позволяет буровой бригаде оценивать скорость проникновения не только на стадии планирования работ, но и во время бурения. Результаты моделирования показали, что нейронная сеть превосходит обычные методы прогнозирования скорости бурения.

Яшодхан Гид и другие [12] так же использовали искусственную нейронную сеть для разработки системы оптимизации параметров бурения. Их целью было продлить срок использования буровых долот путем подбора наиболее оптимальной скорости бурения и нагрузки на долота. Используя данную модель, рабочие параметры бурения могут быть выбраны на основе зафиксированных характеристик горных пород, в которые предполагается осуществить бурение, а затем точно настроены для конкретных условий.

В другой публикации скорость бурения наряду с удельной механической энергией Рашиди Б. и Ниггардом Р. [13] использовались для расчета износа долота в режиме реального времени. Были получены положительные результаты, а именно линейная зависимость между уравнением удельной механической энергии и усилием при дроблении

горной породы, связанные между собой выведенной константой. Анализируя большое количество операций, авторы считают, данный поход может стать ценным инструментом в анализе износа долота в режиме реального времени.

Мустафа М. Амер и другие [14] для прогнозирования скорости бурения применили обучение модели по методу обратного распространения, который показал свою успешность в данном примере.

Валисевич А. и другие [15], используя искусственную нейронную сеть была создана модель, оптимизирующая отработки долот в режиме реального времени. Все это привело к увеличению скорости бурения, снижению износа долота в течение бурения.

Другое применение нейронной сети нашли Дашевский Д. и другие [16]. Использование нейронной сети позволило гораздо более точно моделировать нелинейную буровую систему, путем наблюдения за ее динамическим поведением. Авторами была достигнута основная цель работы – использования нейронных сетей для интеллектуального контроля за бурением в динамике.

Гирирадж Кумар С. М. [17] для улучшения бурения предлагают использовать оптимально настроенный пропорционально-интегрально-дифференциальный контроллер, используемый в высокопроизводительной системе бурения. Основная цель работы состояла в том, чтобы получить стабильную, надежную и контролируемую систему путем настройки ПИД-регулятора с использованием алгоритма оптимизации роевых частиц. Итоги работы показали, что настройка ПИД-регулятора с использованием РИ (роевой интеллект) дает меньшее перерегулирование.

С использованием ИНС Линд Ю. Б. и другие создали алгоритм прогнозирования поглощения буровых растворов [1]. Данная система позволяет получать рекомендацию по выбору буровых растворов.

Статические методы обучения для прогнозирования крутящего момента и силы трения в режиме реального времени применил Чирант Хегд и Кен Грей [18]. Они рассмотрели такие алгоритмы как регрессию,

случайные лес и метод опорных векторов. Эти методы могут быть использованы для прогнозирования проблем бурения и принятия соответствующих мер по их устранению. Например, неожиданное изменение значения крутящего момента может быть признаком осложнения.

Другое распространенное осложнение – нестабильность стенок скважины с помощью нейронной сети получилось спрогнозировать Окпо Е. Е. и др. [19]. Технология нейронной сети использовалась для прогнозирования геомеханических параметров пласта. Модель была разработана в Neuroph Studio, платформе нейронной сети Java и Netbeans IDE. Главным преимуществом модели является ее простота и открытый исходный код.

Шон Унрау и другие [20] с помощью метода машинного обучения улучшили существующую систему сигнализации аварий на буровой. Стандартные системы сигнализации неадекватны для обнаружения осложнений, потому что они генерируют слишком много ложных тревог, которые существенно влияют на рабочий процесс. Предложенный авторами алгоритм машинного обучения, может быть использован для уменьшения срабатывания ложных тревог при сохранении жестких границ срабатывания сигнализации. Модель успешно обнаруживает проявления и поглощения.

4. КЛАССИФИКАЦИЯ ОСЛОЖНЕНИЙ ПРИ БУРЕНИИ

Как было отмечено выше, интеграция методов искусственного интеллекта в бурение имеет большое прикладное значение. Цель настоящей работы научить модель классифицировать осложнения в процессе бурения.

К осложнениям и авариям в процессе бурения принято относить нарушения технологического процесса строительства скважин, которые требуют для их ликвидации дополнительного времени, а также специальных работ [3].

Буровая бригада постоянно сталкивается с множеством сложных ситуаций, выходы из которых могут быть очень дорогостоящими, а то и просто невозможными (рис. 4).




Рисунок 4 - Типичные осложнения при бурении [21]

При бурении может произойти прихват бурильной колонны, посредством прижатия к стенке скважины перепадом давления или застрять в результате наработки желоба. Для ликвидации данных осложнений потребуется применение дополнительных усилий для освобождения буровой

колонны. Иногда эти усилия могут не увенчаться успехом. Тогда ничего не остается, как оставить захваченную часть колонны и произвести зарезку нового ствола в обход нового.

Бурение пород с разломами и трещинами неизбежно сопровождается поглощениями бурового раствора. Также слишком высокое давление бурового раствора на забое может привести к разрыву породы и вызвать потерю циркуляции. Использование облегченного бурового раствора с целью предотвращения поглощения нецелесообразно исходя из безопасности проведения буровых работ. Слишком легкий раствор не сможет подавить нефтегазопроявление из пласта, тем самым вызвав опасность выброса. Обрушение стенок скважины в случае их неустойчивости может повредить трубы, либо сделать невозможным дальнейший процесс бурения.

Некоторые из этих осложнений, даже если они не полностью приостанавливают процесс бурения, могут вызвать значительные проблемы: простой буровой, осложнения при заканчивании и освоении скважины [21].

Трохов Т.А. и Степанов С. Ю. в своей статье приводят следующую классификацию осложнений при бурении, которая кратко описывает проблемы с которыми приходится встречаться буровой команде (рис. 5).

Принятие решения по устранению этих проблем является сложным процессом. Ущерб от осложнений складывается из затраченного времени на ликвидацию осложнения, затрат на материалы, энергию. Таким образом предупреждения осложнений и соответственно сведение к минимуму рисков их возникновения является на сегодняшний день актуальной проблемой.




Рисунок 5 - Классификация осложнений

5. ВЛИЯНИЕ ОСЛОЖНЕНИЙ НА ПАРАМЕТРЫ БУРЕНИЯ

В качестве входных параметров для обучения алгоритма будут использоваться параметры бурения, которые регистрируются в процессе строительства скважины. Подробно рассмотрим основные из них.

5.1. Параметры бурения

Параметры бурения могут быть классифицированы на два типа: параметры, связанные с буровой/долотом, и параметры пласта. Параметры буровой/долота могут непосредственно напрямую регулироваться; однако параметры пласта необходимо обрабатывать по-разному. Ниже будет дана краткая характеристика каждого из параметров бурения. Некоторые из которых будут потом в дальнейшем использоваться при расчетах в данном проекте.

5.1.2. Частота вращения в минуту

Этот параметр представляет собой скорость вращения бурильной колонны. С изобретением системы верхнего привода считывание напрямую связано с электроникой самого блока. Считается, что измерения для этого параметра точны до тех пор, пока настройка системы сбора данных была полностью сделана [22].

5.1.2. Параметры насоса

К параметрам насоса относится его размер, ход насоса и давление насоса. Если одновременно работают два насоса, то должны быть записаны параметры как для первого, так и для второго насоса. Число ходов в минуту передается так же, как и частота вращения в минуту. Давление на насосе может быть сравнено с давлением на входе. Давление насоса всегда должно быть больше давления на входе. Использование расходомеров также может быть использовано для более точного замера расхода.

5.1.3. Наклонение – азимут

Параметры наклона и азимута отвечают за направление бурения. Эффективная связь между блоками контроля бурового раствора и блоком «Измерения во время бурения» считается выгодной для параметров наклона и азимута, что может быть очень важно для поддержания устойчивости стенок скважины.

5.1.4. Нагрузка на долото

Нагрузка на долото представляет собой количество веса, приложенное на долото. Вес на долото затем передается на породу, которые представляет собой энергию, создаваемую вместе со скоростью трубы, продвигает бурильную колонну. Было установлено, что увеличение в два раза частоты вращения долота в породе с напряжением 6000 фунтов на квадратный дюйм при сохранении постоянной нагрузки на долоте привело к 70 % увеличению скорости проходки, однако при увеличении нагрузки на долото в два раза - скорость бурения увеличилась более чем на 300 %. Стоит отметить, что в

данном случае очень важно состояние шарошек долота, поскольку при бурении происходит затупление зубьев в зависимости от характеристик пласта.

5.1.5. Механическая скорость проходки

Скорость бурения является самым важным параметром по сравнению с другими параметрами, принимая во внимание тот факт, что все вычисления основаны на оценке скорости проходки. Скорость бурения измеряется путем относительного изменения положения долота во времени.

5.1.6. Свойства бурового раствора

Реологические свойства и плотность буровых растворов также относятся к очень важным параметрам, которые должны быть зарегистрированы для целей оптимизации процесса бурения. Обычно плотность бурового раствора измеряется через калиброванные датчики измерения плотности раствора. С другой стороны, реологические свойства все еще измеряются вручную. Недавние разработки в отношении трубчатых вискозиметров в реальном времени диктуют альтернативные решения. В лаборатории проводятся экспериментальные исследования с использованием трубчатых вискозиметров.

5.1.7. Крутящий момент

Этот параметр является крутящим моментом бурильной колонны во время вращения бурильной колонны. Крутящий момент измеряется с

помощью системы верхнего привода. Крутящий момент имеет важное значение для наклонных скважин, что также связано с процессом очистки ствола скважины.

5.1.8. Каротаж во время бурения

Данный параметр позволяет контролировать пространственное положение ствола скважины по отношению к геологическим объектам. Обычно используется гамма-каротаж и резистивиметрия.

5.2. Признаки осложнений в процессе бурения

По результатам рассмотрения осложнений, которые встречаются в процессе бурения и параметров бурения была составлена следующая таблица 3. В ней использованы следующие технологические показатели:

- $Q_{\text{вх}}$ – расход на входе;
- $Q_{\text{вых}}$ – расход на выходе;
- $P_{\text{вх}}$ - давление на входе;
- $P_{\text{вых}}$ – давление на выходе;
- G – вес на крюке;
- R_s - газосодержание;
- v – скорость проходки;
- M – крутящий момент на роторе;
- H – уровень в ёмкостях;
- V – объем ёмкостей.

Для классификации происшествий использован следующий бинарный алфавит: 0 – физический ноль; 1 – отклонение значения параметра в сторону

уменьшения; 2 – значение параметра находится в пределах нормы; 3 – отклонение параметра в сторону увеличения.

На практике обычно измеряют лишь часть из приведенных в таблице параметров. Может оказаться, что среди параметров нет признаков, однозначно характеризующих ситуацию, которую необходимо распознать. В этом случае применение метода машинного обучения, либо нейронной сети позволяют использовать не только признаки, непосредственно характеризующие распознаваемую ситуацию, но и весь комплекс признаков, даже если они не изменяются при возникновении данной аварии.

Таблица 3 - Признаки осложнений в процессе бурения

Осложнение	$Q_{вк}$	$Q_{вых}$	$P_{вк}$	$P_{вых}$	G	R_s	v	M	H	V
НГВП (ранняя стадия)	2	3	3	3	2	2	3	2	3	3
НГВП (выход на поверхность)	2	3	3	3	2	2	3	2	3	3
Потеря циркуляции (частичная)	2	1	1	1	2	2	3	2	1	1
Потеря циркуляции (полная)	2	0	1	1	2	2	3	2	0	0
Повреждение бурильной колонны	2	2	1	2	1	2	0	0	2	2
Заклинивание долота	2	2	2	2	2	2	2	3	2	2
Нестабильность стенок скважины	2	2	3	2	3	2	1	3	2	2
Прихват	2	2	3	2	3	2	0	3	2	2

6. ИСХОДНЫЕ ДАННЫЕ ДЛЯ СОЗДАНИЯ МОДЕЛИ

Перед началом анализа исходных данных хотелось бы отметить, что в глобальном масштабе, нефтяные и газовые компании ежегодно тратят на бурение около 20 миллиардов долларов на бурение скважин. Порядка 15% (рис. 6) это суммы уходит на ликвидацию аварий, простои из-за задержки оборудования [21].



Рисунок 6 - Затраты нефтегазовых компаний на бурение скважин, млрд \$

В качестве исходных данных были предоставлены отчеты по бурению 67 скважин. Многие из скважин имеют осложнения, которые привели к простоям и потере продуктивного времени бурения. Анализ суммарного времени, затраченного на бурение всех скважин показал, что около 9% от этого числа составляет непродуктивное время работы (рис. 7).

Стоит отметить, что 9% это существенная цифра, учитывая, что в среднем стоимость одного часа буровой варьируется в пределах 15-55 тыс. рублей. А на данном месторождении имеется скважина у которой непроизводительное время составляет 50% от общего времени работы.



Рисунок 7 - Распределение времени работы при бурении скважин на месторождении X

Основные причины непроизводительного времени бурения представлены на рисунке 8. Наибольшие потери времени были из-за простоев в ожидании подрядчиков, оборудования, ожидания работ. Потом идет непроизводительное время по причине ликвидации брака (внеплановые проработки, перебуры по вине подрядчика и т.д.). В данной работе нас интересуют осложнения возникающие в процессе бурения. К ним относятся НГВП, потеря циркуляции, осложнения ствола скважины.




Рисунок 8 - Распределение непроизводительного времени при бурении скважин на месторождении X

Были выбраны и проанализированы скважины с осложнениями. Стоит отметить, что из 67 скважин, 20 скважин были пробурены без затрат на непроизводительное время. Наиболее распространенной проблемой является прихваты, возникающие при спуске обсадных колонн. Стоит отметить, что в данной работе будут произведены расчеты с осложнениями, возникающими непосредственно во время бурения. Под это ограничение подпадают три скважины. В которых осложнения возникли во время бурения.

Для дальнейшего анализа были рассмотрены все параметры бурения, которые записывались для каждой скважины. Анализ данных показал, что из все выборки не все скважины имеют соответствующее число параметров. На некоторых скважинах была произведена запись минимального числа параметров. Хотелось бы отметить, что отчеты по бурения были предоставлены по 67 скважинам, но файлов с записанными параметрами бурения дано по 78 скважинам. Поэтому анализ параметров проводился по 78 скважинам. Из рисунка 9 видно, что лишь 8 параметров являются наиболее встречающимися во всех скважинах, которые выделены красным цветом. И именно эти параметры в дальнейшем будут использоваться как входные параметры для прогнозирования осложнений.




Рисунок 9 - Рейтинг параметров бурения

После проделанной работы для трех скважин в которых были осложнения были построены графики записанных параметров бурения. Графики построены с использованием языка программирования Python.

Скважина 1. Осложнение связано с потерей устойчивости ствола скважины из-за попадания технической воды на глубине 2882 метра (рис. 10). Можно отметить, что данное осложнение сопровождается резкими изменениями в параметрах бурения. В частности, резко увеличивается значение веса на крюке, крутящего момента на роторе и т.п. На ликвидацию данной проблемы буровой бригадой был затрачен 231 час времени.

Скважина 2. При бурении в интервале 239-263 м произошло поглощение бурового раствора в объеме 40 м^3 (рис. 11). На поглощение было затрачено 7.1 час непроизводительного времени. Стоит отметить, что на графике отчетливо видно, что во время поглощения значительно уменьшается уровень ёмкости 01.

Скважина 3. При бурении 2493 м произошло поглощение бурового раствора. Общее поглощение составило 55 м^3 (рис. 12). Для ликвидации осложнения была закачена кольматирующая пачка. Общее время, затраченное на борьбу с осложнением составило 27.9 часов. Данная скважина одна из тех, у которой была произведена запись не всего перечня необходимых параметров бурения.




Рисунок 10 - Скважина 1. Потеря устойчивости ствола скважины




Рисунок 11 - Скважина 2. Потеря циркуляции




Рисунок 12 - Скважина 3. Потеря циркуляции

7. ИСПОЛЬЗУЕМЫЕ АЛГОРИТМЫ ДЛЯ СОЗДАНИЯ МОДЕЛИ

С целью создания программы, классифицирующей осложнения в процессе бурения были подобраны основные методы машинного обучения, с помощью которых будет производиться расчет. Их краткий обзор представлен ниже.

7.1. Логистическая регрессия

Логистическая регрессия является мощным статистическим способом моделирования биномиального результата с помощью одной или нескольких объясняющих переменных. Он измеряет взаимосвязь между категориально-зависимой переменной и одной или несколькими независимыми переменными путем оценки вероятностей с использованием логистической функции, которая является совокупным логистическим распределением [32].

Логистическая функция, также называемая сигмоидной функцией. Она была разработана для решения задач статистики, связанной с описанием свойств роста популяции в экологии, быстро возрастающей и максимизирующейся при пропускной способности окружающей среды. Это S-образная кривая, которая может принимать любое вещественное число и отображать его в значениях от 0 до 1, но никогда точно в этих пределах.

$$\frac{1}{1 + e^{-x}} \quad (7.1)$$

Где e - основание натурального логарифма, а ' x ' - это фактическое числовое значение, которое вы хотите преобразовать. Ниже приведен график (рис. 13) чисел от -5 до 5, преобразованных в диапазон 0 и 1 с использованием логистической функции.




Рисунок 13 - Логистическая регрессия [32]

7.2. Наивный байесовский классификатор

Это метод классификации, основанный на теореме Байеса с предположением о независимости между переменными. Проще говоря, наивный байесовский классификатор предполагает, что наличие определенной функции в классе не связано с наличием какой-либо другой функции. Например, плод можно считать яблоком, если он красный, круглый и около 3 дюймов в диаметре. Даже если эти параметры зависят друг от друга или от наличия других параметров, наивный байесовский классификатор будет рассматривать все эти свойства независимо друг от друга, чтобы создать вероятность того, что этот плод является яблоком.

Наивная байесовская модель легко построить и он особенно полезен для очень больших наборов данных. Наряду с простотой, наивный байесовский классификатор, как известно, превосходит даже очень сложные методы классификации [34].

Теорема Байеса дает способ вычисления апостериорной вероятности $P(c | x)$ из $P(c)$, $P(x)$ и $P(x | c)$. Рассмотрим уравнение представленное ниже:

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (7.2)$$

Где,

- $P(c|x)$ – вероятность гипотезы (c) при наступлении события (x);
- $P(c)$ – априорная вероятность гипотезы (c);
- $P(x|c)$ - вероятность наступления события (x) при истинности гипотезы (c);
- $P(x)$ – полная вероятность наступления события (x).

7.3. Метод k-ближайших соседей

При распознавании образов алгоритм k-ближайших соседей (k-NN) является непараметрическим методом, используемым для классификации и регрессии. В обоих случаях вход состоит из k ближайших примеров обучения в пространстве функций. Выход зависит от того, используется ли k-NN для классификации или регрессии:

- В классификации k-NN параметр на выходе представляет собой принадлежность классу. Объект классифицируется большинством голосов его соседей, причем объект присваивается классу, наиболее распространенному среди его ближайших к ближайшему соседу (k - положительное целое число, обычно маленькое). Если $k = 1$, то объект просто присваивается классу этого единственного ближайшего соседа.
- В регрессии k-NN параметр на выходе является значением свойства для объекта. Это значение является средним значением его k ближайших соседей.

K-NN - это тип обучения на основе алгоритма с отложенными вычислениями, где функция только аппроксимируется локально, и все

вычисления откладываются до классификации. Алгоритм k-NN является одним из самых простых алгоритмов машинного обучения.

Как для классификации, так и для регрессии может быть полезно присвоить вес вкладам соседей, чтобы более близкие соседи вносили больший вклад в средний, чем более отдаленные. Например, общая схема взвешивания состоит в том, чтобы дать каждому соседу вес $1/d$, где d - расстояние до соседа.

Соседи берутся из набора объектов, для которых известен класс (для классификации k-NN) или значение свойства объекта (для k-NN-регрессии). Это можно рассматривать как набор тренировок для алгоритма, хотя не требуется явного этапа обучения.

Особенностью алгоритма k-NN является то, что он чувствителен к локальной структуре данных [35].

7.4. Дерево принятия решений

Дерево принятия решений - это простой и широко используемый метод классификации. Он применяет простую идею для решения проблемы классификации. Дерево принятия решения представляет собой ряд тщательно продуманных вопросов об атрибутах тестовой записи. Каждый раз, когда он получает ответ, задается следующий вопрос, пока не будет сделан вывод о метке класса записи [36].

Дерево решений - это графическая модель, описывающая решения и их возможные результаты. Деревья принятия решений состоят из трех типов узлов (рис. 14):

1. Узел принятия решения: часто представлены квадратами, которые показывают решения, которые могут быть сделаны. Строки, выходящие из квадрата, показывают все различные варианты, доступные на узле.

2. Вероятностный узел: часто представлены кругами, показывающими случайные результаты. Шансы исхода - это события, которые могут произойти, но не способные контролировать управляющего.

3. Замыкающий узел: часто представлен треугольниками или линиями, не имеющими дополнительных узлов решения или случайных узлов. Терминальные узлы изображают окончательные результаты процесса принятия решений.




Рисунок 14 - Схема дерева принятия решения [36]

7.5. Метод опорных векторов

Метод опорных векторов (SVM) - относительно новый метод обучения, используемый для двоичной классификации. Основная идея - найти гиперплоскость, которая отлично разделяет d -мерные данные на два класса.

Однако, поскольку данные примера часто не являются линейно разделяемыми, SVM вводит понятие «ядро, индуцированное пространством объектов», которое переводит данные в пространство более высокой размерности, где данные являются разделимыми. Как правило, отбрасывание в такое пространство может вызвать проблемы с вычислительной точки зрения и с переобучением. Ключевое понимание, используемое в SVM, заключается в том, что с пространством с более высоким размером не нужно напрямую обращаться (как оказалось, нужна только формула для точечного произведения в этом пространстве), что устраняет вышеупомянутые проблемы. Кроме того, VC-размер (мера вероятности функционирования системы для невидимых данных) SVM может быть явно рассчитан, в отличие от других методов обучения, таких как нейронные сети, для которых нет никакой меры. В целом, SVM являются интуитивными, теоретически обоснованными алгоритмом, который доказал свою практическую применимость. SVM также были расширены для решения задач регрессии (где система обучается выдаче числового значения, а не классификации «да / нет») [37].

В качестве примера можно привести объекты двух типов. Линия на рисунке 15 разделяет оба типа. Слева объекты желтого цвета, справа коричневого. Если новый объект попадает в левую область, то он классифицируется как желтый.




Рисунок 15 - Разделение классов прямой линией [37]

Цель метода опорных векторов - найти плоскость, разделяющую два множества объектов; такая плоскость показана на рисунке 16. На данном

рисунке все образцы разделены на два класса: коричневые принадлежат классу А; желтые – классу В.




Рисунок 16 - Определение опорных векторов [37]

Метод опорных векторов находит образцы, которые находятся ближе всего к границе между двумя классами, т.е. опорным векторам (рис. 17).




Рисунок 17 - Опорные вектора [37]

7.6. «Случайный лес»

«Случайный лес» представляет собой метод обучения ансамбля для классификации, регрессии и других задач, которые работают путем построения множества деревьев решений во время обучения и вывода класса, который

является классификатором или среднее предсказание (регрессия) отдельных деревьев.

«Случайный лес» является популярным методом для различных задач машинного обучения. Данный алгоритм является инвариантным относительно масштабирования и различных других преобразований значений признаков, включения нерелевантных функций и создание контролируемых моделей. Однако они редко точны [38].

В частности, деревья, которые растут очень глубоко, имеют тенденцию изучать нерегулярные образы: они перерабатывают свои обучающие наборы, то есть имеют низкую предвзятость, но очень высокую дисперсию. «Случайные леса» - это способ усреднения множества глубоких деревьев решений, обученных на разных частях одного и того же набора учебных предметов, с целью уменьшения дисперсии. Это происходит за счет небольшого увеличения предвзятости и некоторой потере интерпретируемости, но в целом значительно повышается производительность в окончательной модели.

7.7. Градиентный бустинг

Градиентный бустинг - это семейство мощных методов машинного обучения, которые продемонстрировали значительный успех в широком спектре практических применений. Они могут настраиваются для конкретных нужд. Например, при изучении отношения различных функций потерь.

Бустинг основан на процедуре последовательного построения композиции алгоритмов машинного обучения, когда каждый последующий алгоритм стремится компенсировать недостатки всех предыдущих алгоритмов. Бустинг представляет собой жадный алгоритм построения композиции алгоритмов. Изначально понятие бустинга возникло в работах по вероятно почти корректному обучению в связи с вопросом: возможно ли, имея

множество плохих (незначительно отличающихся от случайных) алгоритмов обучения, получить хороший [38].

7.8. Нейронная сеть

Искусственные нейронные сети (ANN) - это вычислительные системы, основанные на биологических нейронных сетях, которые составляют мозг животных. Такие системы учатся (постепенно повышают производительность) для выполнения задач, рассматривая примеры, как правило, без специального программирования. Например, при распознавании образов они могут научиться идентифицировать наборы параметров, содержащие осложнения, анализируя изображения примеров, которые вручную помечены как «осложнение» или «нет осложнения», и используя аналитические результаты для идентификации осложнений на других параметры.

ANN основан на наборе связанных единиц, называемых искусственными нейронами (аналогично аксонам в биологическом мозге). Каждое соединение между нейронами может передавать сигнал другому нейрону. Получающий (постсинаптический) нейрон может обрабатывать сигнал (сигналы), а затем сигнализировать о нижестоящих нейронах, подключенных к нему. Нейроны могут иметь состояние, обычно представляемое действительными числами, обычно между 0 и 1. Нейроны и синапсы также могут иметь вес, который изменяется по мере прохождения обучения, что может увеличить или уменьшить силу сигнала, который он посылает вниз по течению. Кроме того, они могут иметь такой порог, что только в том случае, если совокупный сигнал ниже (или выше) этого уровня является передаваемым вниз сигналом.

Как правило, нейроны организованы в слои. Различные слои могут выполнять различные виды преобразований на своих входах. Сигналы

перемещаются от первого (входного), до последнего (выходного) уровня, возможно, после пересечения слоев несколько раз.

Первоначальной целью подхода нейронной сети было решение проблем так же, как и мозг человека. Со временем внимание было сосредоточено на сопоставлении конкретных умственных способностей, приводящих к отклонениям от биологии, таких как обратное распространение, или передаче информации в обратном направлении и корректировке сети для отражения этой информации.

Искусственная нейронная сеть представляет собой взаимосвязанную группу узлов, сродни обширной сети нейронов в мозге. Здесь каждый круговой узел представляет собой искусственный нейрон, а стрелка представляет собой соединение с выхода одного нейрона на вход другого (рис. 18).




Рисунок 18 - Схема нейронной сети

8. ВЫБОР АЛГОРИТМА С ВЫСОКОЙ ТОЧНОСТЬЮ КЛАССИФИКАЦИИ АВАРИЙ

По приведенным в предыдущей главе алгоритмам машинного обучения были произведены расчеты с целью классификации (прогнозирования) осложнений в процессе бурения. Для расчетов использовался язык программирования Python.

Процентное соотношение между обучающей и тестовой выборкой 65/35 %. Обучающая выборка – это выборка на основе которой выбранный алгоритм настраивает модель зависимости. Тестовая выборка – это та выборка по которой проверяется точность используемой модели.

В качестве оценки качества используемых моделей для классификации осложнений в процессе бурения использовались метрики. Для каждого из алгоритмов были введены метрики *precision* (точность), *recall* (полнота) и F-мера [39].

$$precision = \frac{TP}{TP + FP} \quad (8.1)$$

$$recall = \frac{TP}{TP + FN} \quad (8.2)$$

Где,

TP – положительное наблюдение, и как ожидается будет положительно;

FN – наблюдение положительно, но предсказано отрицательно;

FP - наблюдение отрицательно, но предсказано положительно.

Precision это своеобразная доля объектов, которая названа классификатором положительными и при этом данные объекты в самом деле являются положительными. Recall же это метрика показывающая, какую долю объектов положительного класса из всех объектов положительного класса нашел алгоритм (рис. 19).




Рисунок 19 - Метрики precision и recall [39]

Другими словами, precision не позволяет отнести все объекты в один класс, т.к. в данной ситуации будет увеличиваться уровень FP. Recall показывает возможность модели определять данный класс в принципе, а precision – отличать класс от других классов.

F-мера – это агрегированный критерий качества, объединяющий precision и recall – среднее гармоническое precision и recall.

$$F_{\beta} = (1 + \beta^2) \cdot \frac{\text{precision} \cdot \text{recall}}{(\beta^2 \cdot \text{precision}) + \text{recall}} \quad (8.3)$$

Где,

β – вес точности метрики ($\beta=1$ – среднее гармоническое).

F-мера при полноте и точности достигает максимума, равным единицы, и если один из аргументов близок к нулю стремится к нулю.

Данные загружались в программную среду Python загружались единым массивом данных, с предварительной классификацией осложнений, для последующего обучения модели. Как было указано, обучающая выборка составляет 65% от общего числа данных, а 35% данных используются в качестве проверки правильности настройки модели. В качестве входных параметров использовались следующие параметры бурения:

- Давление на входе;
- Уровень ёмкости 02;
- Расход на входе;
- Вес на крюке;
- Крутящий момент на роторе;
- Скорость проходки;
- Объём ёмкости 02;
- Газосодержание.

В результате проведения расчетов были получены следующие метрики, для последующего выявления наиболее точной модели. В приведенной таблице 3 видно, что наибольшей точностью обладают следующие алгоритмы машинного обучения: дерево принятия решений; «случайный лес»; градиентный бустинг.

Дальше было рассмотрено количество правильных и верных предположений при расчете алгоритмов. В таблице 4 представлен случай для ситуаций, когда осложнений нет, а в таблице 5 правильность классификации осложнений. Верно – это количество правильно предсказанных значений; ложь – количество неправильно предсказанных. Из представленных данных видно, что наибольшее количество правильных и точных классификаций ситуаций получается при использовании метода машинного обучения – градиентный

бустинг. Градиентный бустинг (приложение В) позволил с минимальной долей ошибки классифицировать осложнение из имеющегося набора данных.

Таблица 3 - Метрики по моделям

Используемый алгоритм	Метрики (определение осложнения)		
	Precision	Recall	F-мера
Логистическая регрессия	0.00	0.00	0.00
Наивный байесовский классификатор	0.03	1.00	0.06
Метод k-ближайших соседей	0.83	0.64	0.73
Дерево принятия решений	0.97	0.87	0.92
Метод опорных векторов	0.00	0.00	0.00
«Случайный лес»	1.00	0.87	0.93
Градиентный бустинг	1.00	0.93	0.97
Нейронная сеть	0.92	0.51	0.66

Таблица 4 - Точность предсказания нормальной ситуации

Алгоритм	Ситуация	Верно	Ложь
Логистическая регрессия	Норма	3916	1
Наивный байесовский классификатор	Норма	2484	1433
Метод k-ближайших соседей	Норма	3911	6
Дерево принятия решений	Норма	3916	1
Метод опорных векторов	Норма	3917	0
«Случайный лес»	Норма	3917	0
Градиентный бустинг	Норма	3917	0
Нейронная сеть	Норма	3915	2

Таблица 5 - Точность предсказания осложнений

Алгоритм	Ситуация	Ложь	Верно
Логистическая регрессия	Осложнение	45	0
Наивный байесовский классификатор	Осложнение	0	45
Метод k-ближайших соседей	Осложнение	16	29
Дерево принятия решений	Осложнение	6	39
Метод опорных векторов	Осложнение	45	0
«Случайный лес»	Осложнение	6	39
Градиентный бустинг	Осложнение	3	42
Нейронная сеть	Осложнение	22	23

Затем были проанализированы входные параметры по категории значимости, весовым критериям для градиентного бустинга. Наибольшее влияние на работу алгоритма имеет «Давление на входе», «Крутящий момент», «Расход на входе».

- Давление на входе (0.3115)
- Крутящий момент на роторе (0.2709)
- Расход на входе (0.2363)
- Объём ёмкости 02 (0.0704)
- Газосодержание (0.0601)
- Вес на крюке (0.0160)
- Скорость проходки (0.0082)
- Уровень ёмкости 02 (0.0000)

9. ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ

Нефтяная отрасль, как и все другие, стремиться к увеличению рентабельности и производительности. Сокращение расходов и потерь, будь то на технологические процессы или используемые материалы, независимо от существующей экономической ситуации, является ключевой задачей для всех преуспевающих компаний. Улучшение эффективности бурения путем классификации и прогнозирования осложнений – это надежный путь для разведывательных и добывающих компаний к достижению данных целей.

Нефтяная и газовая промышленность испытывает сильное давление с конца 2014 года, когда цены на нефть значительно снизились. Весьма изменчивый международный рынок и избыточное предложение нефти означают, что компаниям придется сокращать затраты. В связи с этим многие нефтегазовые компании значительно сократили свои капитальные затраты.

Вместо того, чтобы сосредоточиться на сокращении капитальных затрат, компании должны смотреть внутрь процессов, чтобы найти способ экономии средств без потери эффективности. В настоящее время большее внимание уделяется технологиям, которые снижают стоимость и повышают эффективность работы предприятия.

С 2003 года технологические инвестиции в добычу нефти и газа превысили 7 миллиардов \$. При этом нефтегазовая отрасль начинает охватывать новые технологии из смежных отраслей. Одними из этих технологий является применение искусственного интеллекта для оптимизации производственных процессов и анализа большого количества данных.

Большие данные это неотъемлемая часть нефтегазовой отрасли. Несмотря на сокращение добычи нефти и газа, существующая разработка месторождений и будущие операции потребуют большей эффективности и производительности. Благодаря анализу основных данных, которые участвуют

в бизнес-решениях, нефтегазовые компании смогут сэкономить на затратах и времени планирования.

И если новые технологии будут внедряться компаниями в добычи нефти и газа, это позволит компаниям в экономии своих затрат. Например, при строительстве буровой установки, достигающую сотен миллионов \$, даже сокращение времени планирования на 5% может оказать значительное положительное влияние прибыль компании [40].

Написанная программа позволяет инженеру вмешаться на ранней стадии в процесс бурения предотвратив осложнения. Например, в приведенной выше скважине 3, простой по причине поглощения бурового раствора составил 27.9 часа. В среднем 1 час работы буровой обходится компании в 45 тысяч рублей. Не сложно подсчитать, сколько компания сможет сэкономить ресурсов в случае раннего предотвращения осложнения. В частности, для данной скважины экономия могла составить 1.255 миллиона рублей.

9.1. Техничко-экономическое обоснование строительства одноствольной скважины

В качестве экономического расчета было выбрано технико-экономическое обоснование строительства скважины на данном месторождении. Исходные данные представлены в таблице 6.

Таблица 6 - Исходные данные

№ п/п	Исходные данные для расчёта	Ед.изм.	Значение
1	Капитальные вложения	т.руб.	21 000
1.1.	в т.ч. стоимость бурения + освоение + отвод земель + + затраты на бурение водозаборн. скв.	т.руб.	21 000
2	Дебит скважины	т/сут	2.5
3	Переменные затраты на извлечение нефти	руб/т	370
4	Ставка НДС	руб/т	4371
5	Цена реализации 1т нефти без НДС	руб/т	8587
6	Норма амортизации скважин	%	9.09
7	Норма дисконтирования	%	10
8	Налог на имущество	%	2.2
9	Налог на прибыль	%	20
10	Коэффициент эксплуатации, $K_{\text{Э}}$		0.95
11	Коэффициент падения добычи, $K_{\text{ПД}}$		0.93

Для оценки экономической эффективности бурения скважины используется система показателей, основными из которых являются:

- чистый дисконтированный доход (ЧДД);
- индекс доходности (ВНР);
- дисконтированный срок окупаемости (ДСО);
- индекс доходности дисконтированных затрат (ИРИ);

Величина коэффициента дисконтирования (η_t) при постоянной норме дисконта (E) определяется выражением:

$$\eta_t = 1 / (1 + E)^t \quad (9.1)$$

Формула расчета чистого дисконтированного дохода имеет вид:

$$ЧДД = \left(\frac{ДП_1}{(1+d)^1} + \frac{ДП_2}{(1+d)^2} + \dots + \frac{ДП_n}{(1+d)^n} \right) - (I_1 + I_2 + \dots + I_n) * (1+d)^n \quad (9.2)$$

или

$$ЧДД = \sum_{n=1}^N \frac{ДП_n}{(1+d)^n} - \sum_{n=1}^N I_n * (1+d)^n \quad (9.3)$$

где $ДП_n$ - поступления денежных средств (денежный поток) от реализации продукции в n-м году;

d - коэффициент дисконтирования учитывающий затраты на страхование рисков, покрытие инфляционных процессов, стоимость капитала привлекаемого для реализации инвестиционного проекта. В расчетах принимается равным 10%;

I_n - начальные инвестиции.

Математическое определение внутренней нормы рентабельности предполагает решение следующего уравнения:

$$\sum_{n=1}^N \frac{ДП_n}{(1+BHP)^n} = I \quad (9.4)$$

где $ДП_t$ - поступления денежных средств (денежный поток) от реализации продукции в t-м году;

I - начальные инвестиции (сумма итога сводного сметного расчета).

Общая формула расчета показателя ДСО имеет вид:

$$ДПО = \frac{I_n * (1+d)^n}{\sum ДП_n * (1+d)^{-n}} \quad (9.5)$$

Расчет индекс доходности дисконтированных затрат производится по формуле:

$$ИРИ = \frac{\sum_{n=1}^N \frac{ДП_n}{(1+d)^n}}{\sum_{n=1}^N I_n (1+d)^n} \quad (9.6)$$

где I_n - начальные инвестиции (сумма итога сводного сметного расчета).

$ДП_n$ - поступления денежных средств (денежный поток) от реализации продукции в n-м году.

В ходе расчетов было доказано экономическая эффективность проекта, при бурении скважины (рис. 20) (табл. 7).




Рисунок 20 – Чистый дисконтированный поток по годам.

Основные показатели экономической эффективности проекта:

- ЧДД – 18 909 тыс. руб;
- Дисконтируемый срок окупаемости – 4.4 года;
- Индекс доходности – 1.193.

Таблица 7 - Расчет экономического эффекта от прироста добычи нефти

[illegible]

10. СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ

Бурение нефтяных скважин является ответственным процессом, качество и безопасность которого обусловлены соблюдением ряда правил и положений, составляющих систему безопасного проведения работ. Четкое следование данным правилам обеспечивает снижение рисков возникновения нештатных ситуаций при бурении скважин. Именно поэтому важное значение отводится определению основополагающих принципов, на основе которых в дальнейшем выстраивается политика предприятия в области промышленной безопасности, охраны труда и охраны окружающей среды.

Месторождение X по климатическим условиям находится в районе Крайнего Севера. Существующие технологии и оборудование для бурения и крепления скважин обуславливает проведение работ на открытом воздухе. Поэтому нужно предусмотреть меры профилактики охлаждения и переохлаждения, а также обморожения: обеспечить работников теплой одеждой и обувью, а также организовать перерывы для обогрева рабочих в специально оборудованном помещении, сократить продолжительность рабочей смены.

10.1. Освещенность

В действующих нормах по проектированию искусственного освещения минимальную освещенность на рабочих местах устанавливают с учетом размеров объектов размещения, разряда работы, контраста объекта различия с фоном и светлоты фона. Отраслевые нормы освещенности рабочих мест на буровой и нормы освещенности согласно СНиП 23-05-95 представлены в таблице 8.

Следовательно, работа персонала относящаяся к 2-3 разряду, имеет освещенность не менее 200-300 лк. В остальных местах буровой установки

работа относится к 4-5 разряду с освещенностью 50-80 лк.

Анализируя отраслевые нормы освещенности приходим к выводу, что они занижены в 3-5 раз по сравнению со СНиП 23-05-95. Это связано с тем, что буровая установка рассматривается не как производственное помещение, а как строительная площадка.

Недостаток света и не рационально устроенное производственное освещение затрудняет деятельность работающих, ухудшает их ориентировку в пространстве, координацию движений, скорость ответных реакций.

Таблица 8 - Нормы освещенности

Рабочие места, подлежащие освещению	Разряд зрительной работы	Место установки светильников	Отраслевая норма освещенности, лк	Рекомендуемая освещенность, лк
Роторный стол	II	На ногах вышки на высоте 4 м под углом 45-50°. Над лебедкой на высоте 4 м под углом 45-50° к вертикали	40	200
Щит КИП	I	Перед приборами	50	220
Полати верхового рабочего	II	На ногах вышки на высоте не менее 2,5 м от пола полатей под углом не менее 50°	25	150
Путь талевого блока	IV	Налестничных площадках, под углом не менее 65-70°	13	80
Кронблок	IV	Над кронблоком	25	80
Приемный мост	IV	На передних ногах вышки на высоте не менее 6 м	13	80
Редукторное помещение	II	На высоте не менее 6 м	30	200
Насосное помещение	II	На высоте не менее 3 м	25	200
Глиномешалки	III	На высоте не менее 3 м	26	200
Превентор	III	Под полом буровой	26	200

10.2. Шум и вибрация

При бурении скважин используются различные машины и механизмы, при работе которых, в ряде случаев увеличивается уровень шума и вибраций, к ним относятся: электромоторы, лебедки, вибросита, буровые насосы, ротор и др. Шум и вибрация оказывают вредное воздействие на организм человека. Сильный шум нарушает нормальную деятельность нервной, сердечнососудистой и пищеварительной системы, вызывает переутомление. Вредное воздействие вибрации выражается в возникновении вибрационной болезни.

Для того, чтобы снизить вредное воздействие шумов и вибраций на буровой необходимо производить своевременный профилактический осмотр и ремонт, подтягивание ослабевших соединений, своевременно смазывать вращающиеся детали.

Если подавить шум в источнике возникновения невозможно, то следует применять звукопоглощающие и звукоизолирующие экраны ПП-80, ПА/О, ПА/С.

Для борьбы с вибрацией применяют следующие методы:

- 1) подавление в источнике возникновения (центровка, регулировка);
- 2) изменение в конструкции;
- 3) использование пружинных амортизаторов, виброизоляционных прокладок.

Уровни вибраций в соответствии с гигиеническими нормами, установленными ГОСТ 12.1.012.-90 представлены в таблице 8, уровень шума на рабочих местах по ГОСТ 12.1.003-83 в таблице 9.

Таблица 8 - Уровни вибраций

Виды вибраций	Направление по которому нормируется вибрация	Среднеквадратичные значения виброскорости, м/с · 10 ⁻²							
		Уровни вибрации, дБ в среднегеометрических частотах октавных полос, Гц							
		1	2	4	8	16	31,5	63	125
Технологические на постоянных рабочих местах	Вертикальная (на оси) или горизонтальная (по осям)	-	1,3 108	0,45 99	0,22 93	0,2 92	0,2 92	0,2 92	-

Таблица 9 - Шум на рабочих местах

Характеристика помещений	Уровень звукового давления, дБ в среднегеометрических частотах октавных полос, Гц							
	63	125	250	500	1000	2000	4000	8000
Постоянные работы, рабочие зоны и места в производственных помещениях и территории предприятия	99	92	86	83	80	78	76	74

Основными источниками шума на буровой являются: роторный стол до 115 дБ, буровая лебедка до 96 дБ, вибросито 98 дБ. При бурении ротором шум составляет до 115 дБ, при спускоподъемных операциях до 105 дБ.

В связи с этим имеем превышение уровней шумов над нормами по ГОСТ 12.1.003-83 на 13-31 дБ.

10.3. Источники опасности для персонала на буровой

Источниками опасности для персонала на буровой, прежде всего, являются различные движущиеся части механизмов, тяжелые и крупногабаритные инструменты, химические вещества, шумы, вибрации, живая природа.

Движущиеся части механизмов (лебедка, насосы, ротор, цепные приводы) во избежание несчастных случаев ограждаются предохранительными кожухами и защитными поверхностями.

Опасность *тяжелых и крупногабаритных инструментов* состоит, прежде всего, в возможности их падения на персонал, что может привести к тяжелым последствиям - травмам, увечьям, летальному исходу.

Химические вещества, применяемые в производстве, имеют различные свойства. Тяжесть и глубина действия различных вредных веществ на организм человека зависит от вида веществ и его физико-химических свойств.

Таблица 10 - Вредные вещества в бурении и добыче (ГОСТ 17.1.3.12-86)

Вещество	ПДК, мг/м ³	Класс опасности
Соляная кислота (HCl)	5	2
Серная кислота (H ₂ SO ₄)	1	2
NaOH, KOH	0,5	2
Кальцинированная сода (Na ₂ CO ₃)	2	3
NaCl, KCl	5	3
Барит (BaSO ₄)	6	4
Нефть	10	3
Углеводороды предельные C ₁ -C ₁₀	300	4
СО	20	4
Глинопорошки	4	4
Цемент	6	4
ПАВы (сульфанол, детергент и др.)	3	4
КМЦ (карбоксиметилцеллюлоза)	10	3
Полимеры и сополимеры на основе ПАН (гипан, метас)	10	3
ПАА (полиакриламид), Кем-Пас, Поли КемД	10	3
ДК-дрилл, сайпан	2	4

Почти все вещества, вредные для организма применяются в современной технологии добычи нефти и газа. При этом они оказывают общее токсическое, раздражающее, канцерогенное и мутагенное действие на человека, представляя по этой причине опасность для его здоровья и жизни.

В каждой отрасли промышленности имеются свои источники загрязнения, которые представляют некоторую опасность для жизнедеятельности людей. В нефтяной промышленности таковыми являются сырая нефть, двуокись углерода, сероводород, сернистый ангидрид, детергенты, природный газ, бензин, предельные углеводороды, окись углерода.

10.4. Энергобезопасность

В бурении используются электроустановки как низкого напряжения до 1000 В, так и высокого выше 1000 В.

Основным источником электротравматизма в бурении являются установки низкого напряжения. Лица, работающие на электроустановках, проходят соответствующее обучение, им присваивается классификационная группа I - V по технике безопасности. Бурильщики и помощники должны иметь группу не ниже II. Согласно "Правилам техники безопасности при эксплуатации электроустановок потребителей", лица II группы должны иметь элементарное техническое знакомство с электроустановками, отчетливо представлять опасность электрического тока и приближение к токоведущим частям, знать основные меры предосторожности при работах в электроустановках, а также иметь практическое знакомство с правилами оказания первой помощи.

Основными мерами защиты при эксплуатации электроустановок являются: надежная изоляция пускорегулирующих аппаратов, контактов магнитных пускателей, автоматов, цепей автоматического электропривода.

10.5 Требования по охране труда для рабочих при бурении скважин

1. К самостоятельному выполнению работ по бурению скважин допускаются лица, возраст которых соответствует установленному законодательством, прошедшие медицинский осмотр в установленном порядке и не имеющие противопоказаний к выполнению данного вида работ, имеющие соответствующую квалификацию и допущенные к самостоятельной работе в установленном порядке. Перед допуском к самостоятельной работе рабочий проходит стажировку в течение 2 – 14 смен (в зависимости от характера работы, квалификации работника) под руководством специально назначенного лица.

2. Рабочий, выполняющий работу при помощи электроинструмента, должен иметь группу по электробезопасности не ниже II.

3. Периодический медосмотр рабочий проходит в порядке, установленном Минздравом Республики Беларусь.

4. Повторную проверку знаний безопасных методов работ рабочий должен проходить не реже одного раза в 12 месяцев.

Внеочередную проверку знаний рабочий проходит в следующих случаях:

- при перерыве в работе по специальности более одного года;
- по требованию вышестоящей организации, ответственных лиц предприятия;

- при переходе с одного предприятия на другое;

5. Рабочий должен пройти инструктажи по безопасности труда:

- при приеме на работу — вводный и первичный на рабочем месте;
- в процессе работы не реже одного раза в 6 месяцев — повторный;
- при введении в действие новых или переработанных правил, инструкций по охране труда, замене или модернизации оборудования, приспособлений и инструмента, нарушении требований безопасности труда, которые могут привести или привели к травме или аварии, перерывах в работе более чем 60 календарных дней — внеплановый.

6. Знать санитарно-гигиенические условия труда и соблюдать требования производственной санитарии.

- знать требования, изложенные в инструкциях (паспортах) заводо-изготовителей оборудования и инструкции по охране труда;
- пользоваться при выполнении работ средствами индивидуальной защиты, выдаваемыми в соответствии с Типовыми отраслевыми нормами, бесплатной выдачи рабочим и служащим специальной одежды, специальной обуви и других средств индивидуальной защиты (табл. 11);
- уметь оказывать доврачебную помощь пострадавшему;
- выполнять правила внутреннего трудового распорядка;
- иметь четкое представление об опасных и вредных производственных факторах, связанных с выполнением работ, и знать основные способы защиты от их воздействия: недостаточная освещенность рабочей зоны, повышенная или пониженная температура воздуха рабочей зоны, повышенная концентрация вредных веществ в воздухе рабочей зоны, острые кромки, заусенцы и шероховатость инструментов и оборудования, движущееся и вращающееся механизмы и оборудование.

7. Рабочий не должен подвергать себя опасности и находиться в местах производства работ, которые не относятся к непосредственно выполняемой им работе.

8. О каждом несчастном случае на производстве пострадавший или очевидец немедленно должен сообщить непосредственному руководителю работ, который обязан:

- организовать первую помощь пострадавшему и его доставку в медицинский пункт;
- сообщить о случившемся руководителю подразделения;
- сохранить до начала работы комиссии по расследованию обстановку на рабочем месте и состояние оборудования таким, каким они были на момент происшествия, если это не угрожает жизни и здоровью окружающих работников и не приведет к аварии.

Таблица 11 - СИЗ

№п/п	Наименование
1	Костюм хлопчатобумажный 3Ми - 12 мес.
2	Рукавицы хлопчатобумажные с накладками из винил кожи - Т
3	Ботинки кожаные Мп – 12 мес.
4	Каска защитная - 24 мес.
5	Очки защитные – до износа
<i>На наружных работах зимой дополнительно</i>	
6	Куртка хлопчатобумажная на утепляющей прокладке Тн – 36 мес.
7	Брюки хлопчатобумажные на утепляющей прокладке Тн – 36 мес.
8	Валяная обувь Тн20 - 48 мес.
9	Галоши на валяную обувь - 24 мес.
10	Подшлемник - 24 мес.

9. Обо всех замеченных неисправностях оборудования, инструмента и приспособлений рабочий должен сообщить непосредственному руководителю работ и до их устранения к работе не приступать.

10. Рабочий несет ответственность за:

- выполнение требований инструкций (паспортов) заводов—изготовителей оборудования и инструкции по охране труда, правил пожаро и электробезопасности;
- соблюдение правил внутреннего трудового распорядка;
- качественное выполнение работ;
- сохранность закрепленного за ним оборудования, приспособлений и инструмента;

- аварии, несчастные случаи и другие нарушения, причиной которых явились действия рабочего, нарушающего требования инструкций (паспортов) заводов-изготовителей оборудования и инструкции по охране труда.

11. Рабочий должен оказывать содействие и сотрудничать с нанимателем в деле обеспечения здоровых и безопасных условий труда, немедленно извещать своего непосредственного руководителя или иное должностное лицо нанимателя о неисправности оборудования, инструмента, приспособлений, транспортных средств.

12. Рабочий, появившийся на работе в нетрезвом состоянии, в состоянии наркотического или токсического опьянения, не допускается к работе в этот день (смену).

13. Зимой при работе на открытом воздухе необходимо делать перерывы для обогрева или полностью прекращать работы при следующих температурах:

- при температуре -10°C — перерыв на 10 минут для обогрева через каждый час работы;
- при тихой погоде и температуре равной -20°C — перерыв на 10 минут для обогрева через каждый час работы;
- при температуре воздуха -30°C — работы прекращаются.

ЗАКЛЮЧЕНИЕ

В результате проведенного комплексного анализа пробуренных скважин на месторождении X были выявлены скважины в которых во время бурения возникали осложнения. Было установлено, что в результате осложнений доля непроизводительного времени от общего времени бурения составило 9%, что является значительной долей затрат для компании. Предварительное

Обзор литературы показал актуальность проблематики прогнозирования и классификации осложнений в процессе бурения. Наиболее популярными методами оптимизации процесса бурения в последние несколько лет являются методы машинного обучения.

Для классификации осложнений в процессе бурения были использованы наиболее эффективные методы машинного обучения. Для алгоритмов были выбраны параметры бурения, которые будут поступать на вход в программу, для ее обучения и дальнейшего прогнозирования осложнений. В результате проведенных расчетов, был выбран наиболее точный метод машинного обучения – градиентный бустинг. Данный метод показал наименьшую ошибку при тестовом испытании классификации осложнений. Из всех параметров бурения большее влияние на классификатор оказывает давление на входе.

В результате работы можно утверждать, что был подобран алгоритм, который с минимальной погрешностью способен классифицировать осложнения в процессе бурения на основе параметров, записываемых на буровой. Такая программа поможет инженеру вовремя вмешаться в процесс бурения и предотвратить высокие расходы на простой и ремонт оборудования.

Рекомендуется для дальнейшей работы над проектом включить в работу большее количество скважин с осложнениями для более точной настройки программы на классификацию различных осложнений.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Линд Ю. Б., Самсыкин А. В., Галеев С. Р. Информационно-аналитическая система предупреждения поглощений буровых растворов. SPE доклад был подготовлен для презентации на сессии молодых специалистов Российской технической конференции SPE, 26 – 28 октября, 2015, Москва.
2. Чучалина К. Ю. Особенности геологического строения и критерии, и признаки прогнозирования углеводородов в низкопроницаемых коллекторах на примере Новопортовского нефтегазоконденсатного месторождения: бакалаврская работа / Томский политехнический университет. – 2017. – 109 л.
3. Щепетов О.А. Системная классификация аварий в бурении. – М.:2009. – 7 с.
4. Ali J. K., British Gas PLC. «Neural Networks: A New Tool for the Petroleum Industry?», paper was prepared for presentation at the European Petroleum Computer Conference held in Aberdeen, U.K., 16-17 March, 1994.
5. Sheng Zhan, Jens Rodiek, Ludger Ewald Heuermann-Kuehn and Joerg Baumann, Prognostics Health Management for a Directional Drilling System. Baker Hughes Incorporated, 2011 – 7 p.
6. Yanfang Wang, Drilling Hydraulics Optimization Using Neural Networks. University of Louisiana, 2014 – 74 p.
7. Fatih Camci and Ratna Babu Chinnam. Dynamic Bayesian Networks for Machine Diagnostics: Hierarchical Hidden Markov Models vs. Competitive Learning. Wayne State University, Detroit, 2005 – 6 p.
8. Yuliya B. Lind, Aigul R. Kabirova. Artificial Neural Networks in Drilling Troubles Prediction. SPE paper 171274-MS was prepared for presentation at the SPE Russian Oil and Gas Exploration and Production Technical Conference and Exhibition held in Moscow, Russia, 14–16 October 2014.
9. Abdullah Saleh H. Alyami. Using bayesian network to develop drilling expert systems. Texas A&M University, 2012 – 226 p.

10. Jahanbakhshi, R. and Keshavarzi, R. Real-time Prediction of Rate of Penetration during Drilling Operation in Oil and Gas Wells. ARMA paper 12-244 prepared for presentation at the 46th US Rock Mechanics / Geomechanics Symposium held in Chicago, IL, USA, 24-27 June 2012.
11. Mehran Monazami, Abdonabi Hashemi, Mehdi Shahbazian. Drilling rate of penetration prediction using artificial neural network: a case study of one of Iranian southern oil fields. Electronic scientific journal "Oil and Gas Business", 2012, № 6.
12. Yashodhan Gidh, Hani Ibrahim. Artificial Neural Network Drilling Parameter Optimization System Improves ROP by Predicting/Managing Bit Wear. SPE paper 149801 was prepared for presentation at the SPE Intelligent Energy International held in Utrecht, The Netherlands, 27–29 March 2012.
13. Rashidi B. and Nygaard R. Real-Time Drill Bit Wear Prediction by Combining Rock Energy and Drilling Strength Concepts. SPE paper 117109 was prepared for presentation at the 2008 Abu Dhabi International Petroleum Exhibition and Conference held in Abu Dhabi, UAE, and 3–6 November 2008.
14. Mustafa M. Amer, Dr. Prof. Abdel Sattar DAHAB. An ROP Predictive Model in Nile Delta Area Using Artificial Neural Networks. SPE paper 187969-MS was prepared for presentation at the SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition held in Dammam, Saudi Arabia, 24–27 April 2017.
15. Валисевич Алексей, Ружников Алексей, Бебешко Иван, Жентичка Максим. Система оптимизации буровых долот: Увеличение механической скорости проходки и мониторинг износа долота в режиме реального времени. SPE доклад 176517-RU был подготовлен для презентации на Российской нефтегазовой технической конференции SPE, 26 – 28 октября, 2015, Москва.
16. Dashevskiy D., Dubinsky, V. and Macpherson J. D. Application of Neural Networks for Predictive Control in Drilling Dynamics. SPE paper 56442 was prepared for presentation at the 1999 SPE Annual Technical Conference and Exhibition held in Houston, Texas, 3–6 October 1999.

17. GirirajKumar S. M., Deepak Jayaraj, Anoop.R.Kishan. PSO based Tuning of a PID Controller for a High Performance Drilling Machine. International Journal of Computer Applications, 2010, Volume 1 – No. 19.
18. Chiranth Hegde, Scott Wallace, and Ken Gray. Real Time Prediction and Classification of Torque and Drag During Drilling Using Statistical Learning Methods. SPE paper 177313-MS was prepared for presentation at the SPE Eastern Regional Meeting held in Morgantown, West Virginia, USA, 13–15 October 2015.
19. Okpo E. E., Dosunmu A., and Odagme B. S. Artificial Neural Network Model for Predicting Wellbore Instability. SPE paper 184371-MS was prepared for presentation at the SPE Nigeria Annual International Conference and Exhibition held in Lagos, Nigeria, 2–4 August 2016.
20. Sean Unrau. Machine Learning Algorithms Applied to Detection of Well Control Events. SPE paper was prepared for presentation at the SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition held in Dammam, Saudi Arabia, 24–27 April 2017.
21. Walt Aldred et al. Managing drilling risk. Oilfield review, 1999, 18 p.
22. Yanfang Wang, and Saeed Salehi. Drilling Hydraulics Optimization Using Neural Networks. SPE paper was prepared for presentation at the SPE Digital Energy Conference and Exhibition held in The Woodlands, Texas, USA, 3–5 March 2015.
23. Altman, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. The American Statistician, 1992, 46 (3): 175–185.
24. Hastie, Trevor; Tibshirani, Robert; Friedman, Jerome. The Elements of Statistical Learning (2nd ed.), 2008, 50 p.

Использованные интернет ресурсы

25. http://www.nftn.ru/oilfields/russian_oilfields/jamalo_neneckij_ao/novop_ortovskoe/7-1-0-168
26. <http://www.geokniga.org/bookfiles/geokniga-kollektiv-avtorov-geologiya-i-poleznye-iskopaemye-rossii-v-shesti-tomah-tom-2.pdf>

27. <http://www.geologam.ru/oil/yamal/formirovanie-i-evolyuciya-novoportovskoy-gruppy>
28. <http://www.geologam.ru/oil/yamal/novoportovskoe-neftegazokondensatnoe-mestorozhdenie>
29. <http://ntc.gazprom-neft.ru/research-and-development/papers/9180/>
30. <http://insights.globalspec.com/article/2772/the-growing-role-of-artificial-intelligence-in-oil-and-gas>
31. <http://www.bogotobogo.com/python/scikit-learn/Artificial-Neural-Network-ANN-1-Introduction.php>
32. <http://www.kdnuggets.com/2016/08/10-algorithms-machine-learning-engineers.html>
33. <http://machinelearningmastery.com/logistic-regression-for-machine-learning/>
34. <https://www.analyticsvidhya.com/blog/2015/08/common-machine-learning-algorithms/>
35. https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm#cite_note
36. http://mines.humanoriented.com/classes/2010/fall/csci568/portfolio_exports/lguo/decisionTree.html
37. <http://dustwell.com/PastWork/IntroToSVM.pdf>
38. http://www.machinelearning.ru/wiki/index.php?title=%D0%91%D1%83%D1%81%D1%82%D0%B8%D0%BD%D0%B3#cite_note-0
39. https://chrisalbon.com/machinelearning/precision_recall_and_F1_scores.html
40. <http://biarri.com/driving-efficiency-oil-gas-industry/>

ПРИЛОЖЕНИЕ А

Раздел (3,8)

(The existing experience of using artificial intelligence in drilling: Definition of the algorithm with high accuracy of the classification of problem)

Студент:

Группа	ФИО	Подпись	Дата
2TM51	Григорьев Алексей Сергеевич		

Консультант кафедры _____ ГРHM _____:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Зав. кафедрой ГРHM	Чернова О. С.	К.Г.—М.Н., доцент		

Консультант — лингвист кафедры _____ ПОНК _____:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Максютин К.Ю.	к.п.н.		

3 THE EXISTING EXPERIENCE OF USING ARTIFICIAL INTELLIGENCE IN DRILLING

The requirements of the practice of drilling deep oil and gas wells require a broad range of needs for the theory. In this case, the theory should explain the flow of drilling technological processes both in typical regimes and at the time of the onset of complications and during development, treating complications as an integral part of such procedures. It is desirable that a theoretical description of difficulties allows judging them not only at a qualitative level, but also quantify the interrelation of their essential variables. Because of the rather narrow applied nature of modelling tasks and prevention of complications, their formulation and evaluation of the results obtained should first of all be guided by the needs and possibilities of practice. The existing capabilities of computer technology make it possible to carry out calculations that several years ago seemed laborious.

Let us briefly review the existing works, which were aimed at improving the drilling process using neural networks and machine learning.

Shen Zhang et al. [5] in their work used a nonparametric system of fuzzy inferences to predict the state of the rotary controlled system. This method allows you always to update the forecast status of the ENG based on the parameters of drilling and operating conditions in real time. This reduces the cost of repairs and maintenance.

Yangfang Wang [6] presented an approach that uses neural programming techniques, such as multi-layer neural network modelling to predict nonlinear drilling optimisation problems. The model proposed by him can not only predict the pump pressure, as the desired parameter but also can ensure the impact of each input parameter in this model.

Several successive incidents usually accompany mechanism of destruction of a mechanical system on the way to loss of efficiency. Therefore, monitoring the health of the tool, even if the machine is working properly, is very necessary for detecting, identifying and locating the fault (i.e., diagnostics) and estimating the remaining

useful life of the component/machine. So Fatih Kamchi and others [7] with the help of the hidden Markov model make it possible to assess the state of the machine's working capacity with the aid of observed signals from sensors. In particular, this model was used to determine the condition of the drill bits.

At present, methods of neural programming networks for solving problems in various fields have been widely used. An artificial neural network is an interconnected group of nodes, similar to our brain system. Figure 1 shows the neural network scheme. There are three layers, each circle is a neuron, and the line is a connection between neurons. The first layer has input neurons that send data through communication lines to the second layer of neurons, and then through a large number of link nodes to the third layer of output neurons [31].




Figure 1 - Diagram of the neural network [31]

For example, Lind Yu.B. and Kabirov AR [8] used a neural network to predict probable problems that may arise when drilling wells based on information about oil field reserves. The results of the computational experiments showed the effectiveness of the developed software.

The Bayesian neural network was used in his work by Abdullah Saleh H. Allami [9]. Based on the results of the work, an expert system for drilling was developed, which can be used as training for young engineers or as a system of

consultations at various stages of drilling design. The Bayesian model was used to develop well completion models, to select drilling fluids, to control drilling and cementing wells, and to work under high pressure.

Drilling engineers in the field of drilling are always looking for methods for predicting unexpected situations in the drilling process and the corresponding improvement in the parameters associated with this. Forecasting drilling speed is given considerable attention due to its influence on the optimisation of various parameters, which directly leads to a reduction in costs. Jahabakhshi R. and Keshavarzi R. used a neural network to predict drilling speed [10]. As input parameters, parameters such as rock type, mechanical properties of the formation, hydraulics, type of bit and its features, rotor speed as parameters are considered as they are deemed to be the most important for predicting the rate of penetration. Mehran Monazami and others [11] in their article also use a neural network to estimate drilling speed. This method is considered by the authors as the most useful tool in forecasting in comparison with the currently available procedures. The model allows the drilling crew to assess the penetration rate not only at the planning stage but also during drilling. The simulation results showed that the neural network is superior to conventional methods of predicting drilling speed.

Yashodhan Guide and others [12] also used an artificial neural network to develop a system for optimising drilling parameters. Their goal was to extend the life of the drill bits by selecting the most optimal drilling speed and bit load. Using this model, the operating parameters of the drilling can be chosen based on the fixed characteristics of the rocks in which it is planned to drill, and then precisely adjusted for specific conditions.

In another publication, the drilling speed along with the specific mechanical energy of Rashidi B. and Niggard R. [13] were used to calculate the bit wear in real time. Positive results have been obtained, namely the linear relationship between the equation of specific mechanical energy and the force in the fragmentation of the rock, related to each other by the deduced constant. Analyzing a large number of

operations, the authors believe that this campaign can be a valuable tool in the analysis of bit wear in real time.

Mustafa M. Amer and others [14] used the model of the backward propagation method to predict the drilling speed, which showed its success in this example.

Valisevich A. and others [15], using an artificial neural network, a model was created optimising the development of bits in real time. All this led to an increase in drilling speed, a decrease in bit wear during drilling.

Another application of the neural network was found by D. Dashevsky and others [16]. The use of a neural network made it possible to model the nonlinear drilling system much more accurately, by observing its dynamic behaviour. The authors have achieved the primary goal of the work - the use of neural networks for the intelligent control of drilling in dynamics.

Giriraj Kumar, SM [17] for the improvement of drilling suggest using the optimally tuned proportional-integral-differential controller used in the high-performance drilling system. The primary purpose of the work was to obtain a stable, reliable and controlled system by tuning the PID controller using the optimisation algorithm for swarm particles. The results of the work showed that tuning the PID controller using RI (swarm intelligence) gives a smaller overshoot.

Using INS, Lind J. Yu. B. and others created an algorithm for predicting the absorption of drilling fluids [1]. This system allows you to receive a recommendation for the selection of drilling fluids.

Static training methods for predicting torque and friction in real time were applied by Cyrant Hegd and Ken Gray [18]. They considered algorithms such as regression, random forest, and support vector method. These methods can be used to predict drilling problems and take appropriate measures to eliminate them. For example, an unexpected change in the value of torque may be a sign of a complication.

Another common complication - the instability of the walls of the well with the help of a neural network was predicted by Oekpo EE et al. [19]. The technology of the neural network was used to predict the geomechanical parameters of the

formation. The model was developed in Neuroph Studio, the platform of the neural network Java and Netbeans IDE. The main advantage of the model is its simplicity, open source code.

Sean Unrau and others [20], using the machine learning method, improved the existing alarm system on the drilling rig. Standard alarm systems are inadequate to detect complications because they generate too many false alarms that significantly affect the workflow. The machine learning algorithm proposed by the authors can be used to reduce false alarms while maintaining strict alarm limits. The model successfully detects manifestations and absorption.

8 DEFINITION OF THE ALGORITHM WITH HIGH ACCURACY OF THE CLASSIFICATION OF PROBLEM

According to the algorithms of machine training given in the previous chapter, calculations were made to classify (forecast) the complications in the drilling process. For calculations, the Python programming language was used.

Percentage between training and test sample 65/35%. The training sample is a sample based on which the chosen algorithm adjusts the dependency model. The test sample is the sample by which the accuracy of the model used is checked.

Metrics were used to assess the quality of the models used to classify the complications in the drilling process. For each of the algorithms, precision (precision), recal (completeness), and F-measure metrics were introduced [39].

$$precision = \frac{TP}{TP + FP} \quad (8.1)$$

$$recal = \frac{TP}{TP + FN} \quad (8.2)$$

Where,

TP - positive observation, and expected to be positive;

FN - observation is positive, but it is predicted negatively;

FP - observation is negative, but predicted positively.

Precision is a kind of share of objects, which is called a positive classifier, and in this case, these objects are in fact positive. Recall is a metric indicating which fraction of objects of a positive class from all objects of a positive class found an algorithm (Figure 2).

In other words, precision does not allow you to assign all objects to one class because, In this situation, the FP level will increase. Recall shows the possibility of the model to define this type in principle, and precision - to distinguish the class from other classes.




Figure 2 - The precision and recall metric [39]

The F-measure is an aggregated quality criterion that combines precision and recall-average harmonic precision and recall.

$$F_{\beta} = (1 + \beta^2) \cdot \frac{\text{precision} \cdot \text{recall}}{(\beta^2 \cdot \text{precision}) + \text{recall}} \quad (8.3)$$

Where,

β is the weight of the accuracy of the metric ($\beta = 1$ is the average harmonic).

F-measure for completeness and accuracy reaches a maximum of one, and if one of the arguments is close to zero, it tends to zero.

The data loaded into the Python software environment was loaded with a single data set, with a preliminary classification of the complications, for the subsequent learning of the model. As indicated, the training sample is 65% of the total data, and 35% of the data is used to verify the correctness of the model set. The following drilling parameters were used as input parameters:

- Inlet pressure;
- Level of tank 02;
- Input flow;
- Weight on the hook;
- Torque on the rotor;
- Rate of penetration;
- Volume of tank 02;
- Gas content.

As a result of the calculations, the following metrics were obtained, for the subsequent detection of the most accurate model.

Table 1 - Metrics by model

Algorithm	Metrics		
	Precision	Recall	F-meapa
Logistic regression	0.00	0.00	0.00
Naive Bayesian Classifier	0.03	1.00	0.06
Method of k-nearest neighbors	0.83	0.64	0.73
Decision tree	0.97	0.87	0.92
Support vector method	0.00	0.00	0.00
«Random Forest»	1.00	0.87	0.93
Gradient boosting	1.00	0.93	0.97
Neural network	0.92	0.51	0.66

Table 1 shows that the following algorithms of machine learning have the highest accuracy: decision tree; "Casual forest"; Gradient boosting.

Next, we considered the number of correct and correct assumptions in the calculation of algorithms. Table 2 presents the case for situations where there are no complications, and in Table 3 the classification of complications is correct. True is the number of correctly predicted values; false is the number of misplaced predictions. From the data presented, it can be seen that the greatest number of correct and accurate classifications of situations is obtained using the machine learning method - gradient boosting. Gradient boosting (Appendix B) allowed with a minimum of error to classify the complication from the available data set.

Table 2 - Accuracy of prediction of a normal situation

Algorithm	Situation	True	False
Logistic regression	Normal	3916	1
Naive Bayesian Classifier	Normal	2484	1433
Method of k-nearest neighbors	Normal	3911	6
Decision tree	Normal	3916	1
Support vector method	Normal	3917	0
«Random Forest»	Normal	3917	0
Gradient boosting	Normal	3917	0
Neural network	Normal	3915	2

Table 3 - Precision of prediction of problems

Algorithm	Situation	True	False
Logistic regression	Problem	45	0
Naive Bayesian Classifier	Problem	0	45
Method of k-nearest neighbors	Problem	16	29
Decision tree	Problem	6	39
Support vector method	Problem	45	0
«Random Forest»	Problem	6	39
Gradient boosting	Problem	3	42
Neural network	Problem	22	23

Then, input parameters were analysed by significance category, weighting criteria for gradient boosting. The greatest influence on the operation of the algorithm is "Input pressure", "Torque", "Flow rate at the input".

- Inlet pressure (0.3115)
- Torque on the rotor (0.2709)
- Inlet flow rate (0.2363)
- Volume of tank 02 (0.0704)
- Gas content (0.0601)
- Weight on the hook (0.0160)
- Rate of penetration (0.0082)
- Level of tank 02 (0.0000)

ПРИЛОЖЕНИЕ В. Пример реализации градиентного бустинга

```
In [16]: # Gradient Boosting
from sklearn import datasets
from sklearn import metrics
from sklearn.ensemble import GradientBoostingClassifier
# fit a Gradient Boosting model to the data
clf = GradientBoostingClassifier()
clf.fit(X_train, y_train)
print(clf)
# make predictions
expected = y_test
predicted = clf.predict(X_test)
# summarize the fit of the model
print(metrics.classification_report(expected, predicted))
print(metrics.confusion_matrix(expected, predicted))

importances = clf.feature_importances_
indices = np.argsort(importances)[::-1]

print("Feature importances:")
for f, idx in enumerate(indices):
    print("{:2d}. feature '{:2d}' ({:.4f})".format(f + 1, indices[idx], importances[idx]))
```

Рисунок – Пример реализации градиентного бустинга