

На правах рукописи



Кодиров Шахбоз Шарифович

**АЛГОРИТМЫ ОБРАБОТКИ ДАННЫХ И НЕЙРОСЕТЕВЫЕ МОДЕЛИ
ПРОГНОЗИРОВАНИЯ ПРИХВАТА ТЕХНОЛОГИЧЕСКОГО БУРОВОГО
ИНСТРУМЕНТА**

Специальность 2.3.1 – системный анализ, управление и обработка информации,
статистика

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
кандидата технических наук

Челябинск – 2022

Работа выполнена в ФГАОУ ВО «Южно-Уральский государственный университет
(национальный исследовательский университет)»

Научный руководитель: **Шестаков Александр Леонидович**, доктор технических наук, профессор, заведующий кафедрой «Информационно-измерительная техника» ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)»

Официальные оппоненты: **Клячкин Владимир Николаевич**, доктор технических наук, профессор, профессор кафедры «Прикладная математика и информатика» ФГБОУ ВО «Ульяновский государственный технический университет»

Абу-Абед Фарес Надимович, кандидат технических наук, доцент, декан факультета международного академического сотрудничества, доцент кафедры «Электронные вычислительные машины» ФГБОУ ВО «Тверской государственный технический университет»

Ведущая организация: ФГБОУ ВО «Санкт-Петербургский горный университет»

Защита состоится 28 ноября 2022 г. в 15:00 часов на заседании диссертационного совета 24.2.437.02, созданного на базе ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)», по адресу: 454080, г. Челябинск, пр. им. В.И. Ленина, 76, ауд. 1007.

С диссертацией можно ознакомиться в библиотеке ФГАОУ ВО «Южно-Уральский государственный университет (национальный исследовательский университет)», а также по ссылке: <https://www.susu.ru/ru/dissertation/24243702-d-21229803/kodirov-shahboz-sharifovich>.

Отзывы на автореферат в двух экземплярах, заверенные печатью, просим высылать по адресу 454080, г. Челябинск, пр. им. В.И. Ленина, 76, ЮУрГУ, Ученый совет, тел. (351) 267-91-23.

Автореферат разослан «___» ____ 2022 г.

Ученый секретарь
диссертационного совета,
д.т.н., доцент



А.В. Голлай

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность темы исследования. Одной из основных целей буровых компаний, во время буровых работ, является минимизация затрат непроизводительного времени. К непроизводительному времени (НПВ) относится время, затраченное на ремонт бурового оборудования, а также на различные внеплановые вспомогательные работы и простои, связанные с ликвидацией аварий и осложнений. НПВ негативно влияет на технологические и экономические показатели эффективности буровых работ, следовательно, и на себестоимость скважины или эксплуатируемого продукта скважины.

Как показывают статистические промысловые данные, основную долю НПВ (от 25% до 70%) составляет время, потраченное на ликвидацию прихвата технологического инструмента.

Прихватом технологического инструмента (ТИ) при буровых работах считается непредвиденная ситуация, характеризующаяся невозможностью извлечения из скважины колонны бурильных труб с компоновкой низа бурильной колонны, несмотря на способность или неспособность расхаживать их или вращать.

Доля прихвата составляет от 26% до 60% от общего числа аварий, встречающихся в процессе строительства скважины. Как показывают аналитические данные, в 10% случаев, возникшие прихваты удается ликвидировать более чем за 4 часа, а в 50% случаев, менее чем за 4 часа. В остальных 40% случаев, возникшие прихваты не удается ликвидировать, вследствие чего пробуривается новый ствол или скважина ликвидируется. Кроме того, из-за прихватов происходят значительные экологические ущербы, например, при ликвидации прихватов ствол скважины, в том числе не обсаженные интервалы, заполняются нефтью или другими вредными химическими реагентами, которые частично просачиваются в пласты горных пород, и могут даже попасть в водоносные горизонты. Соответственно, по выше перечисленным причинам прихват является одним из самых тяжелых и затратных видов аварий, встречающихся при буровых работах.

Прихват можно предотвратить, если правильно распознавать начальные условия и признаки-причины их возникновения, и после предпринимать своевременные меры по их предотвращению. Однако достоверное распознавание начальных условий и признаков-причин возникновения прихватов – является сложной задачей, поскольку одни и те же условия и признаки в разных ситуациях и операциях могут интерпретироваться по-разному. Для этого потребуется разработать алгоритмы обработки данных и модели прогнозирования и

распознавания прихвата ТИ, учитывающие большой перечень ряда универсальных факторов, влияющих на процесс возникновения прихвата.

Таким образом, задача разработки алгоритмов обработки данных и методов прогнозирования и распознавания прихватов – является одной из ключевых проблем буровых предприятий нефтегазового комплекса и является актуальной в научном аспекте и практически значимой.

Цель работы – создание алгоритмов обработки данных и нейросетевых моделей прогнозирования прихвата технологического инструмента, учитывающие в качестве элементов входных данных ряд существенных факторов прихвата, для обнаружения прихватов на ранних стадиях их возникновения.

Задачи исследования, решенные в соответствии с указанной целью:

1) Произвести преобразование элементов данных по глубине ствола скважины, имеющих номинальную шкалу измерения, в данные с относительной шкалой измерения, позволяющие использовать их в качестве входных данных в нейронной сети.

2) На основе полносвязанной и модульной нейронной сети разработать модель прогнозирования прихвата технологического инструмента по глубине ствола скважины, учитывающая в качестве элементов входных данных существенные факторы возникновения прихвата. А также на основе этой модели, разработать алгоритм обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины.

3) Для набора данных по времени бурения, рассчитать и ввести дополнительный элемент данных – *длина технологического инструмента, находящегося в зоне открытого ствола*, который является важным фактором процесса возникновения прихвата. А также произвести декомпозицию данных о процессе возникновения и ликвидации прихвата на подпроцессы, и произвести сегментацию многомерных временных данных по этим подпроцессам, с целью формирования обучающего набора.

4) На основе полносвязанной нейронной сети разработать модель прогнозирования прихвата технологического инструмента по времени бурения скважины, учитывающая в качестве элементов входных данных широкий диапазон факторов и признаков возникновения прихвата, а также тренд изменений значений этих элементов данных. Соответственно, на основе этой модели, разработать алгоритм обработки данных для прогнозирования прихвата технологического инструмента по времени бурения скважины.

5) Провести исследование эффективности работы моделей прогнозирования прихвата технологического инструмента по глубине и по времени бурения скважины на реальных экспериментальных тестовых данных.

Предметом исследования являются методы и алгоритмы обработки данных для прогнозирования прихвата технологического инструмента.

Научная новизна:

1. Предложен метод преобразования элементов данных по глубине ствола скважины, имеющих номинальную шкалу измерения, таких как типы горных пород, компоненты понизителя вязкости, понизителя водоотдачи, ингибирующей и смазывающей добавки, в данные, с относительной шкалой измерения, учитывающий долевые значения этих элементов данных и повышающий информативность входных данных нейронной сети.

2. Разработана новая модель прогнозирования прихвата технологического инструмента по глубине ствола скважины, на основе четырехмодульной нейронной сети, учитывающая в качестве элементов входных данных, данные о свойствах и параметрах скважины и бурения, являющиеся факторами прихвата. Кроме того, предложен алгоритм обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины, позволяющий поинтервально произвести процедуру прогнозирования.

3. Предложен метод расчёта и учета дополнительного элемента данных, $X_{3,20}$ – длина технологического инструмента, находящегося в зоне открытого ствола, для набора данных по времени бурения, позволяющий учитывать дополнительный фактор прихвата.

4. Предложен метод декомпозиции данных о процессе возникновения и ликвидации прихвата на четыре подпроцесса, такие как Y_1 – предприхватный подпроцесс, Y_2 – прихватный подпроцесс, Y_3 – послеприхватный подпроцесс и Y_4 – штатный подпроцесс. Предложен ряд критериев распознавания этих подпроцессов из числа причин и признаков возникновения прихватов. А также предложен метод сегментации многомерных временных рядов из набора данных по времени бурения по четырем подпроцессам прихвата, с применением критериев распознавания этих подпроцессов, позволяющий получить обучающую выборку по четырем подпроцессам.

5. Разработана новая модель прогнозирования прихвата технологического инструмента по времени бурения скважины, на основе шестислойной полносвязанной нейронной сети. В разработанной модели применялись данные о статических и динамических свойствах, параметрах и режимах бурения, что

позволило полученной модели быть более чувствительной и универсальной к данным из скважин других месторождений. Данная модель учитывает тренд изменения значений свойств, параметров и режимов бурения за 30 - минутный временной интервал. Кроме того, предложен алгоритм обработки данных для прогнозирования прихвата технологического инструмента по времени бурения, позволяющий исключить ложный прогноз на прихват в обсаженных интервалах ствола скважины во время спускоподъемных и других технологических операций.

Теоретическая значимость работы заключается:

- в предложенном методе преобразования элементов данных по глубине ствола скважины, имеющих номинальную шкалу измерения, таких как типы горных пород, компоненты понизителя вязкости, понизителя водоотдачи, ингибирующей и смазывающей добавки, в данные, с относительной шкалой измерения, учитывающем долевые значения этих элементов данных и повышающем информативность входных данных нейронной сети;

- в предложенном методе расчёта и учета дополнительного элемента данных, $X_{3,20}$ – длины технологического инструмента, находящегося в зоне открытого ствола, для набора данных по времени бурения;

- в предложенном методе декомпозиции данных о процессе возникновения и ликвидации прихвата на четыре подпроцесса, такие как Y_1 – предприхватный подпроцесс, Y_2 – прихватный подпроцесс, Y_3 – послеприхватный подпроцесс и Y_4 – штатный подпроцесс, и критериев распознавания этих подпроцессов, из числа причин и признаков возникновения прихватов. Кроме того, в предложенном методе сегментации многомерных временных рядов из набора данных по времени бурения по четырем подпроцессам прихвата, с применением критериев распознавания этих подпроцессов;

- в разработанных нейросетевых моделях прогнозирования прихвата технологического инструмента по глубине ствола скважины и по времени бурения.

Практическая значимость работы заключается:

- в предложенных алгоритмах обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины (патент РФ №2735794) и по времени бурения (патент РФ №2753289), с применением моделей прогнозирования прихвата по глубине и по времени бурения скважины, которые позволили сократить время процедуры прогнозирования, а также исключить ложные прогнозы в обсаженных интервалах ствола скважины во время спускоподъемных и ряде других технологических операций;

- в созданном программном коде, в котором реализованы разработанные алгоритмы обработки данных и модели прогнозирования прихвата технологического инструмента по глубине ствола скважины и по времени бурения. Результаты работы были приняты к использованию в деятельности ООО «РУСГЕОСЕРВИС», г. Нижневартовск, и ОАО «НАФТУ ГАЗ» Республики Таджикистан, а также были использованы при выполнении части НИР по проекту «Разработка комбинированных методов обработки смешанных данных для интеллектуальных систем мониторинга сложных промышленных систем» (РФФИ г. Челябинск, №20-48-740031, 2020 г.).

Также предполагается дальнейшее развитие результатов диссертации для применения в разработки программного комплекса предиктивной системы «управление бурения» ОАО «НАФТУ ГАЗ», Республики Таджикистана.

Методы исследования основаны на методах системного анализа, методах подготовки больших данных, теории нейронных сетей и машинного обучения, а также методах оптимизации. Для обработки данных, моделирования и визуализации результатов численных расчетов был применен язык программирования Python, с применением библиотеки Pандас, NumPy, Matplotlib, Seaborn, Scikit-learn, а также фреймворка TensorFlow и KERAS.

Основные положения, выносимые на защиту:

1. Метод преобразования элементов данных по глубине ствола скважины, имеющий номинальную шкалу измерения в данные с относительной шкалой измерения.

2. Нейросетевая модель прогнозирования прихвата технологического инструмента по глубине ствола скважины. А также алгоритм обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины.

3. Метод расчёта и учета дополнительного элемента данных, $X_{3,20}$ – длина технологического инструмента, находящейся в зоне открытого ствола, для набора данных по времени бурения.

4. Метод декомпозиции данных о процессе возникновения и ликвидации прихвата на подпроцессы и ряд критериев распознавания подпроцессов, из числа причин и признаков возникновения прихватов. А также метод сегментации многомерных временных рядов из набора данных по времени бурения.

5. Нейросетевая модель прогнозирования прихвата технологического инструмента по времени бурения скважины. А также алгоритм обработки данных

для прогнозирования прихвата технологического инструмента по времени бурения скважины.

Достоверность результатов работы подтверждается корректностью применения методов, экспериментальной проверкой предложенных моделей и алгоритмов на экспериментальных данных реальных скважин, и апробацией основных результатов диссертации на конференциях, а также их практическим внедрением.

Апробация результатов работы. Основные результаты диссертационной работы были доложены на следующих конференциях и семинарах: II Международная научно-практическая конференция «Наука и технологии в нефтегазовом деле» (Кубанский государственный технологический университет, г. Краснодар, 2020 г.); III Международная научно-практическая конференция молодых ученых и специалистов «Технологии будущего нефтегазодобывающих регионов» (РАН, г. Нижневартовск, 2020 г.); XXII Всероссийская научно-техническая конференция по неразрушающему контролю и технической диагностике (г. Москва, 2020 г.); XVIII Всероссийская конференция-конкурс студентов и аспирантов «Актуальные проблемы недропользования», (Санкт-Петербургский горный университет, г. Санкт-Петербург, 2020г.); XVI International Forum-Contest of Students and Young Researchers – «Topical Issues of Rational Use of Natural Resources» (Saint-Petersburg Mining University, St. Petersburg city, 2020); IX Международная научная конференция молодых ученых «Молодые - Научкам о Земле» (Российский государственный геологоразведочный университет имени С. Орджоникидзе «МГРИ-РГГРУ», г. Москва, 2020 г.); 12-th International Youth Scientific and Practical Congress «Oil and Gas Horizons» (Gubkin University, Moscow city, 2020); Международная научная конференция «Цифровая индустрия: состояние и перспективы развития» (ЮУрГУ, г. Челябинск, 2020 г.); XIX Всероссийская конференция-конкурс студентов и аспирантов «Актуальные проблемы недропользования» (Санкт-Петербургский горный университет, г. Санкт-Петербург, 2021 г.); XVII International Forum-Contest of Students and Young Researchers – «Topical Issues of Rational Use of Natural Resources» (Saint-Petersburg Mining University, St. Petersburg city, 2021); 64-я Всероссийская научная конференция «Московского физико-технического института» (МФТИ, г. Москва, 2021 г.).

Реализация результатов исследования. Полученные результаты диссертационной работы были приняты к использованию в деятельности ООО «РУСГЕОСЕРВИС», г. Нижневартовск, Российской Федерации и ОАО «НАФТУ

ГАЗ» Республики Таджикистан. Кроме того, полученные в работе результаты были использованы при выполнении части НИР по проекту «Разработка комбинированных методов обработки смешанных данных для интеллектуальных систем мониторинга сложных промышленных систем» (РФФИ г. Челябинск, №20-48-740031, 2020 г.).

Публикации результатов работы. По материалам диссертационной работы опубликовано 16 работ [1-16], в том числе 3 публикаций в изданиях, включенных в перечень ведущих рецензируемых научных журналов и изданий, рекомендованных ВАК Российской Федерации [1-3], одна статья в рецензируемой зарубежной изданий, индексируемый наукометрической базой Scopus [4]. Получено 2 патента на изобретения [5-6].

Личный вклад автора. Содержание диссертации и основные положения, выносимые на защиту, отражают персональный вклад автора в опубликованные работы. Подготовка к публикации полученных результатов проводилась совместно с соавторами, причем вклад диссертанта был определяющим.

Структура и объем работы. Диссертационная работа состоит из введения, четырех глав, заключения и списка литературы из 117 источников. Диссертационная работа изложена на 145 страницах, включая 44 рисунков, 11 таблиц и 6 приложений.

ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

Во введении обоснована актуальность диссертационной работы, сформулирована цель и отражена научная новизна исследований, показана практическая значимость полученных результатов, представлены выносимые на защиту научные положения.

В первой главе представлена классификация методов распознавания и прогнозирования прихвата ТИ по глубине ствола скважины и по времени бурения скважины. Соответственно, для каждой группы методов выполнен анализ их функционирования и применяемых элементов входных данных, а также отмечены их основные недостатки. Например, в методах распознавания и прогнозирования прихвата ТИ по глубине ствола скважины, перечень элементов входных данных не сформулирован с учетом физико-химических механизмов возникновения прихвата, а также с учетом всех факторов влияющих на процесс возникновения типов прихват. Большинство из существующих методов основаны на алгоритмах машинного обучения, в том числе искусственных нейронных сетях. Но в этих методах, применяемые структуры и конфигурации нейронных сетей, с учетом типов и количеств элементов входных данных, не оптимизированы под решаемую

задачу, а выбраны по умолчанию с минимальными настраиваемыми параметрами. А также, ни в одной работе не применялась концепция модульной нейронной сети, которые в решениях аналогичных задач показывают превосходные результаты.

Что касается методов распознавания и прогнозирования прихватов по времени бурения, то в них также в перечне элементов входных данных не учитываются целые ряды факторов, влияющие на процесс возникновения прихвата. А применяемый перечень элементов входных данных в существующих методах не описывают все протекающие подпроцессы возникновения прихватов, вызванные вследствие различных геомеханических и технологических причин. Следует также отметить, что в методах, получаемые выходные информации обобщенно описывают процесс возникновения прихвата, например, «прихват» и «отсутствие прихвата». В свою очередь, известно, что процесс возникновения прихвата последовательно сопровождается несколькими подпроцессами, например: штатный подпроцесс, предприхватный подпроцесс, прихватный подпроцесс и послеприхватный подпроцесс. А также, в методах, применяемые структуры и конфигурации нейронных сетей, с учетом типов и количеств элементов входных данных, не оптимизированы под решаемую задачу, а выбраны по умолчанию с минимальными настраиваемыми параметрами. Таким образом, работа посвящена разработке моделей и алгоритмов прогнозирования прихвата ТИ по глубине ствола скважины и по времени бурения скважины с учетом ряда важных факторов, влияющих на процесс возникновения прихватов, на основе искусственной нейронной сети с оптимальными параметрами. Сформулированы цели и задачи диссертационного исследования.

Во второй главе представлены этапы обработки данных о прихватах и разработки модели прогнозирования прихвата ТИ по глубине ствола скважины.

В начале главы, по результатам анализа существующей информации о прихватах, механизмах и факторах прихвата, представлена модифицированная классификация прихватов, в зависимости от механизмов, факторов, причин и признаков их возникновения. Данная классификация представлена в виде таблицы, которая впредь будет служить в качестве критериев распознавания признаков подпроцесса возникновения прихвата.

Далее, представлен анализ методов сбора информации о свойствах, параметрах и режимах бурения скважины, по результатам которого предложена классификация набора данных о прихватах по глубине ствола скважины и по времени бурения скважины.

Рассматривается метод преобразования элементов данных, имеющий номинальную шкалу измерения, такие как типы горных пород, компоненты понизителя вязкости, компоненты понизителя водоотдачи, компонент ингибирующей добавки, компонент смазывающей добавки, в данные с относительной шкалой измерения. Суть такого преобразования состоит в разделении элемента данных на несколько субэлементов, с присвоением каждому субэлементу долевого значение в соответствии со своим основным элементом (см. Таблицу 1).

Таблица 1. Преобразование элементов входных данных

X_2 - тип горных пород в предполагаемой зоне прихвата				X_{15} – компоненты понизителя вязкости				X_{16} – компоненты понизителя водоотдачи				X_{17} – компонент ингибирующий добавки				X_{18} – компонент смазывающий добавки			
$X_{2.1}$	$X_{2.2}$...	$X_{2.i}$	$X_{15.1}$	$X_{15.2}$...	$X_{15.j}$	$X_{16.1}$	$X_{16.2}$...	$X_{16.k}$	$X_{17.1}$	$X_{17.2}$...	$X_{17.l}$	$X_{18.1}$	$X_{18.2}$...	$X_{18.m}$
Тип 1, %	Тип 2, %	...	Тип i, %	Компонент 1, %	Компонент 2, %	...	Компонент j, %	Компонент 1, %	Компонент 2, %	...	Компонент k, %	Компонент 1, %	Компонент 2, %	...	Компонент l, %	Компонент 1, %	Компонент 2, %	...	Компонент m, %

Количество субэлемента определяется имеющимся количеством категории в списке элемента, имеющее категориальную переменную. Например, для элемента X_2 - тип горных пород, в предполагаемой зоне прихвата, может иметь до i -го количества субэлементов, таких как $X_{2.1}$ - глина, $X_{2.2}$ - аргиллит, $X_{2.3}$ - песчаник, $X_{2.4}$ - соль, $X_{2.5}$ - алевролит, $X_{2.6}$ - известняк, ... $X_{2.i}$, а для элемента X_{15} - компоненты понизителя вязкости, может иметь до j -го количества субэлементов и т.п. Соответственно, доленое значение для каждого субэлемента определяется исходя из расчета от основного элемента по всем участвующим категориям.

По результатам такого преобразования, образцы имеющегося набора данных о прихватах по глубине ствола скважины составили 35 элементов данных. Такое преобразование позволило повысить репрезентативность выборки для нейронной сети.

Выполнена классификация имеющихся экспериментальных образцов данных о прихватах по глубине ствола скважины на 4 группы, и отмечены целевыми переменными: Y_1 – дифференциальный прихват (под действием перепада давления); Y_2 – прихват в следствие геометрических изменений ствола скважины;

Y_3 – прихват, вследствие зашламования или закупоривания кольцевого пространства; Y_4 – отсутствие прихвата.

Также, рассматривается методика формирования перечня репрезентативных элементов входных данных по глубине ствола скважины. Методика состоит из расчета коэффициентов корреляции и отбора оптимального перечня репрезентативных элементов входных данных по глубине ствола скважины, включающей в себя: *последовательное добавление элементов набора данных и последовательное удаление элементов набора данных.*

С целью более точной оценки обобщенности модели, имеющийся набор данных о прихватах по глубине ствола скважины разделяется на три непересекающихся мини набора: тренировочного, проверочного и тестового. Это делается для того, чтобы разрабатываемую модель обучить на тренировочном мини наборе, а процесс обучения модели оценивать на проверочном мини наборе. Соответственно, по завершению процесса обучения модели, произвести процедуру тестирования обученной модели на тестовом мини наборе. А также, значений элементов этих мини наборов были нормализованы, то есть были приведены к единичной дисперсии (1):

$$X_{\text{норм}g} = \frac{X_g - \bar{X}}{\sigma'}, \quad g = \overline{1, N_0} \quad (1)$$

где \bar{X} – среднее значение по X_g элементу мини набора данных, N_0 – количество элементов мини набора данных ($N_0 = 35$), σ' – среднеквадратическое отклонение.

Далее, описываются этапы методики разработки модели прогнозирования прихвата ТИ по глубине ствола скважины на основе полносвязанной нейронной сети (ПНС). Методика состоит из обоснования и выбора исходной структуры нейронной сети, поиска оптимального количество слоев и нейронов в слоях сети и выбора наилучшего оптимизатора сети.

Так как в решаемой задаче, имеющиеся образцы набора данных о прихватах по глубине ствола скважины классифицируются на 4 группы, и каждый образец с учетом преобразования некоторых элементов данных, состоит из 35 элементов данных, то исходная структура ПНС должна иметь: входной слой с 35 нейронами с линейной или ректификационной «ReLU» функцией активации; выходной слой из 4-х нейронов, так как имеем 4 группы образцов данных.

Следовательно, так как решаемая задача относится к мульти-классовой классификации, то в выходном слое целесообразно применять функцию активации мягкого максимума «Softmax». А также, в качестве *функции ошибки*, использовать

категориальную перекрестную энтропию (*categorical cross-entropy*), которая описывается уравнением (2):

$$L_h = - \sum_{q=1}^{N_3} Y_q \log(\hat{Y}_q), \quad (2)$$

где \hat{Y}_q – предсказанное моделью значение целевой переменной; Y_q – фактическое значение целевой переменной; L_h – мера ошибки, N_3 – количество нейронов в выходном слое сети ($N_3 = 4$).

В качестве оптимизатора процесса обучения исходной сети, был использован оптимизатор «Adam», так как он считается наиболее универсальным среди всех существующих оптимизаторов для большинства задач. А также, в качестве меры или метрики оценки качества работы сети для мониторинга на этапах обучения и тестирования, используется мера «Accuracy» (ACC). Мера ACC описывается выражением (3):

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}, \quad (3)$$

где: TP – (true positive) количество верно предсказанных сетью прихватов; TN – (true negative) количество верно предсказанных сетью отсутствие прихватов; FP – (false positive) количество неверно предсказанных сетью прихватов; FN – (false negative) количество неверно предсказанных сетью отсутствие прихватов.

Данная мера в основном используется в задачах классификации и отображает долю точности работы сети. Под долей точности в данной работе подразумевается вероятность правильного прогнозирования с распознаванием видов прихвата.

Далее, производится поиск оптимального количества слоев и нейронов в слоях. Существуют различные методики и рекомендации по расчету количества слоев и нейронов в слоях, но на практике эти параметры обычно для каждой задачи выбирается индивидуально на основе численных экспериментов.

Постановка задачи параметрической оптимизации, то есть поиска оптимального количества слоев и нейронов в слоях будет следующее:

1. Найти такое минимальное количество слоев в сети

$$l' = [l'_1, l'_2, \dots, l'_r] \rightarrow \min,$$

при которой средняя доля точности работы сети по всем образцам тестового мини набора достигает своего максимума

$$ACC_{test}^{(l')} \rightarrow \max.$$

2. А также найти такое минимальное количество нейронов в слое

$$N^{(l')} = [N_1^{(l'_1)}, N_2^{(l'_2)}, \dots, N_s^{(l'_r)}] \rightarrow \min,$$

при которой средняя доля точности работы сети по всем образцам тестового мини набора достигает своего максимума

$$ACC_{test}^{(N^{(l')})} \rightarrow \max.$$

Следовательно, критерием поиска оптимальных значений количества слоев и нейронов в слоях будет служить средняя доля точности работы сети на тестовом мини наборе.

Соответственно, экспериментальные вычисления были проведены следующим образом: добавлялся промежуточный слой в исходную структуру ПНС, и для этого слоя методом последовательного перебора добавлялись нейроны с шагом 10 нейронов. Далее производилось обучение, проверка и тестирование с оценкой качества работы сети. Процедура повторялась с добавлением новых нейронов до тех пор, пока не было достигнуто неизменность в значении точности работы сети. После того как было достигнуто то состояние, когда от увеличений количества нейронов качество работы сети не улучшалось, экспериментальные вычисления были приостановлены для данного слоя. Далее, добавлялся новый слой, и процедура повторялась для нового слоя.

Результаты серии вычислительных экспериментов показали, что при количестве нейронов в первом слое равное 97, во втором слое 52, а также при 50 эпохах обучения точность работы сети достигает максимума. Для удобства дальнейших расчетов, назовем эту сеть итоговой ПНС.

Далее, уравнениями описывается математическая модель обучения итоговой трехслойной ПНС с алгоритмом обратного распространения ошибки. После чего, пошагово описывается алгоритм обратного распространения ошибки.

Оценка качества работы сети проводилась методом кросс-валидации по K - блокам. Имеющийся набор данных случайным образом подразделялся на 166-блоков мини данных. В качестве обучающей выборки применялись 165 из них, а 1-блок мини данных в качестве проверочного. Данное разбиение блоков позволило проводить обучение сети и оценку ошибки сети на этих данных. Процедура повторялась 166-раз, в результате чего, получено 166 моделей с их оценками качества работы сети ($L_1 \dots L_{166}$). Затем выражением (4) вычислялась средняя ошибка работы модели, на основе разных независимых блоков:

$$L_{\text{mean}} = \frac{1}{166} \sum_{K=1}^{166} L_K. \quad (4)$$

Далее, была произведена серия экспериментальных вычислений с различными оптимизаторами, такими как SGD, Adadelta и Adam, а также с различными

комбинациями функции активации второго и выходного слоя сети. Как показали результаты серии экспериментальных вычислений, максимальная точность работы сети (0,935) была достигнута при использовании оптимизатора Adam с комбинацией функции активации второго и выходного слоя «Sigmoid-Softmax».

Также, описываются этапы разработки модели прогнозирования прихвата ТИ по глубине ствола скважины на основе четырехмодульной нейронной сети. Для успешной разработки модульной сети, необходимо что бы на входы каждого модуля поступали различные части элементов набора входных данных, то есть не знакомые другим модулям части элементов данных. В таком случае, результаты работы полученной модульной сети, будут значительно отличаться от результатов работы полносвязанной сети. Следовательно, предложена модульная сеть, состоящая из четырех модулей, каждый из которых представляет собой трехслойную ПНС, параметры которой были выше рассмотрены. Соответственно, модули между собой имеют идентичные структуры, за исключением входов, которые отличаются по набору и количеству элементов данных. Например, на входы: первого модуля поступают элементы данных описывающие геологические параметры; второго модуля – элементы данных описывающие технологические и реологические параметры бурового раствора; третьего модуля – элементы данных описывающие технико-технологические параметры бурения; четвертого модуля – все элементы данных. Модули между собой построены параллельно, но выходы у них объединены полносвязанными слоями интегратора, который в свою очередь имеет 16 нейронов во входном слое, 128 нейронов в скрытом, и соответственно, 4 во выходном слое, так как имеем 4 группы образцов данных (см. Рис. 1). Предложенная четырехмодульная нейронная сеть построена по стратегии стек-ансамблирование (stacking ensemble strategies). Так как модульные сети относятся к многослойным персептронам, то соответственно методика обучения и выбора параметров сети идентичны с выше рассмотренной методике для полносвязанной нейронной сети.

С целью предотвращения переобучения, в модульной сети применяется структурная регуляризация под названием «прореживание» (dropout), которая во время обучения на вероятностной основе отбрасывает некоторые межнейронные связи в слоях. Также, рассматривается математическое выражение вероятностного прореживания межнейронных связей на примере второго и третьего слоя первого модуля, так как структуры и параметры модулей между собой идентичны.

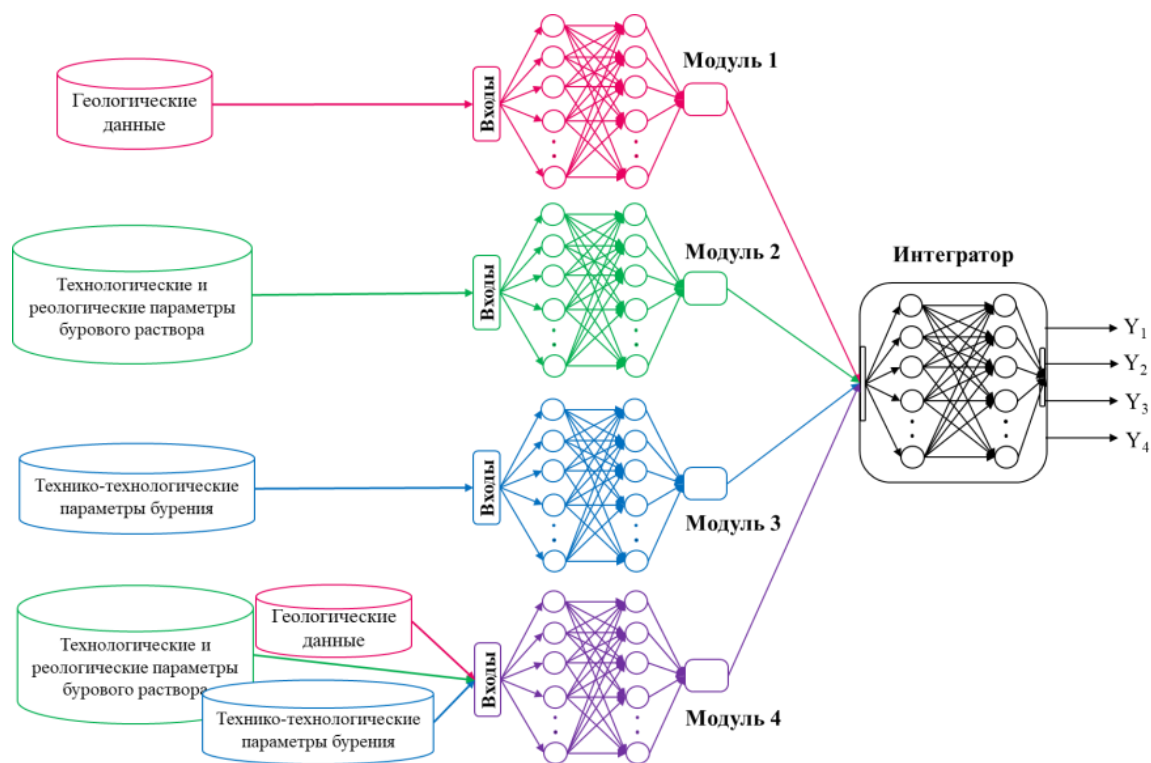


Рис. 1. Архитектура четырехмодульной нейронной сети.

После того как была обоснована четырехмодульная нейронная сеть и ее параметры, которые представлены в таблице 2, были проведены серии вычислительных экспериментов на разнообразных (непересекающихся) выборках данных для оценки качества работы сети.

Таблица 2. Основные параметры четырехмодульной нейронной сети

Параметры сети	Модуль 1	Модуль 2	Модуль 3	Модуль 4	Интегратор
Количество входов	8	22	5	35	16
Количество входов сети, из числа элементов входных данных или выходов модулей и моделей	97	97	97	97	128
Функция активации первого слоя	-	-	-	-	ReLU
Коэффициент прореживания (dropout)	0,3	0,3	0,3	0,3	0,3
Количество нейронов во втором слое	52	52	52	52	52
Функция активации второго слоя	ReLU	ReLU	ReLU	ReLU	Sigmoid
Коэффициент прореживания (dropout)	0,3	0,3	0,3	0,3	-
Количество нейронов в выходном слое	4	4	4	4	4
Функция активации выходного слоя	ReLU	ReLU	ReLU	ReLU	Softmax
Тип функции ошибки сети	Категориальная перекрестная энтропия (Categorical cross-entropy)				
Тип оптимизатора сети	Adam				
Метрика оценка качество работы сети	Accuracy				
Количество эпох обучения сети	40÷80				

Результаты вычислительных экспериментов на тестовом мини наборе показали, что точность работы четырехмодульной нейронной сети, которая имеет

вероятность правильного прогнозирования с распознаванием видов прихвата 0,96, превосходит точность работы полностью связанной сети.

Далее, в работе предлагается алгоритм обработки данных для прогнозирования прихвата ТИ по глубине ствола скважины в процессе проектирования и бурения скважины (см. Рис. 2).

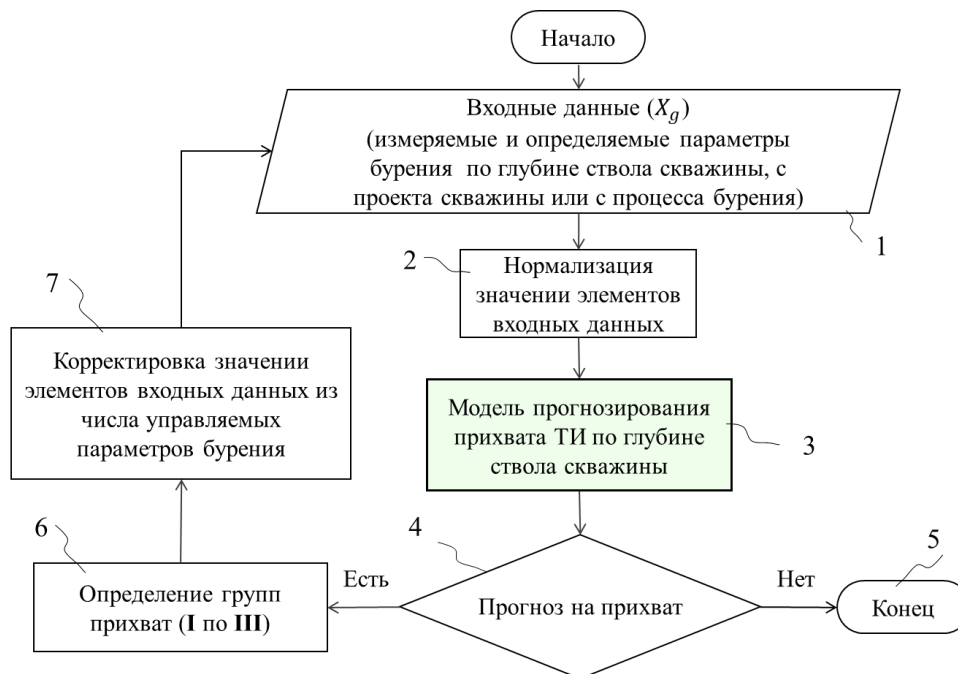


Рис. 2. Алгоритм обработки данных для прогнозирования прихвата ТИ по глубине ствола скважины.

В третьей главе описываются этапы обработки данных и разработки нейросетевой модели прогнозирования прихвата ТИ по времени бурения скважины.

Для полноты описания всех условий, вызывающих процесс возникновения прихвата, а также с целью исключения ложного прогноза на прихват, для набора данных по времени бурения введен параметр, в виде нового элемента данных $X_{3.20}$ – длина технологического инструмента находящегося в зоне открытого ствола. Этот параметр определяется выражением:

$$X_{3.20} = X_{3.7} - h_{bashOK}, \quad (5)$$

при условии, что

$$X_{3.7} > h_{bashOK},$$

где h_{bashOK} – глубина нахождения башмака обсаженной колонны, м; $X_{3.7}$ – глубина нахождения инструмента (долота), м.

Если $X_{3.7} \leq h_{bashOK}$, тогда $X_{3.20} = 0$. Параметр $X_{3.20}$, является одним из важнейших факторов, влияющих на процесс возникновения прихватов. Как известно, в 99% случаев, прихваты происходят в интервалах открытого ствола, то есть при значениях параметра $X_{3.20}$ больше нуля. Соответственно, чем больше значения этого параметра, тем выше риски возникновения прихвата.

Предложен метод декомпозиции данных о процессе возникновения и ликвидации прихвата на четыре подпроцесса, такие как Y_1 – предприхватный подпроцесс, Y_2 - прихватный подпроцесс, Y_3 - послеприхватный подпроцесс и Y_4 - штатный подпроцесс. Такая декомпозиция позволит локализовать все стадии прихвата, особенно начальную стадию, а также позволит в любой момент времени оценить состояния ТИ в стволе скважины на возможные риски возникновения прихвата.

В качестве критериев распознавания подпроцессов прихвата, предлагается использовать причины и признаки возникновения прихватов, перечень которых приведен в таблице классификации прихватов в зависимости от механизмов, факторов, причин и признаков их возникновения.

Предложен метод сегментации многомерных временных рядов из набора данных по времени бурения. В решаемой задаче, под сегментацией набора данных по времени бурения, в виде многомерных временных рядов, подразумевается разделение временного рядов на такие отрезки, на каждом из которых происходил один подпроцесс (Y_1 , Y_2 , Y_3 или Y_4). После чего, сегменты, соответствующие одному и тому же подпроцессу, объединяются, далее из этих объединений формируется выборка.

Соответственно, сегментация набора данных по времени бурения, осуществлялась по четырем подпроцессам прихвата (Y_1 , Y_2 , Y_3 , Y_4), с применением критериев распознавания этих подпроцессов.

По выше рассмотренной методике формирования перечня репрезентативных элементов входных данных был выполнен отбор оптимального перечня элементов входных данных по времени бурения скважины. Анализ результатов вычислений, показал, что из 41 имеющихся элементов входных данных, в том числе слабокоррелирующие, 38 из них имеют весомую значимость, и влияют на качество работы модели.

Далее, описываются этапы разработки нейросетевой модели прогнозирования прихвата ТИ по времени бурения скважины. Разработка нейронной сети была выполнена по выше рассмотренной методике разработки нейросетевой модели прогнозирования прихвата: в начале, выбирается и обосновывается тип и исходная структура нейронной сети, далее, производится поиск оптимального количества слоев и нейронов в слоях сети, а также производится поиск наилучшего типа оптимизатора сети. Следовательно, была обоснована итоговая полносвязанная шестислойная нейронная сеть, структурная схема которой представлена на рисунке 3.

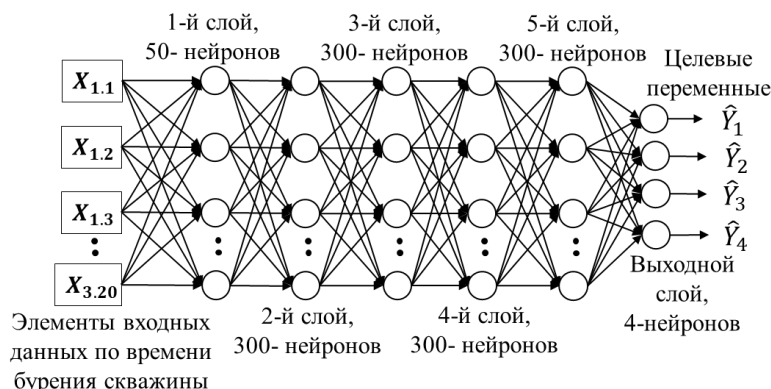


Рис. 3. Структурная схема итоговой полносвязанной шестислойной нейронной сети, для задачи прогнозирования прихвата ТИ по времени бурения скважины.

Для того, чтобы оценить на сколько параметр $X_{3,20}$ влияет на качество работы сети, было проведено повторное обучение и тестирование сети без учета и с учетом элемента $X_{3,20}$ в перечне элементов входных данных сети. В качестве меры оценки качества работы сети помимо точности «ACC» применили такие меры как «Precision» и «Recall» которые описываются выражениями (6) и (7):

$$Precision = \frac{TP}{TP + FP}, \quad (6)$$

$$Recall = \frac{TP}{TP + FN}. \quad (7)$$

Результаты тестирования сети без учета и с учетом элемента данных $X_{3,20}$ представлены в таблицах 3 и 4.

Таблица 3. Результаты тестирования сети без учета и с учетом $X_{3,20}$.

Мера оценки	без учета $X_{3,20}$				с учетом $X_{3,20}$				улучшение качество работы сети, %			
	подпроцессы прихвата				подпроцессы прихвата				подпроцессы прихвата			
	Y_1	Y_2	Y_3	Y_4	Y_1	Y_2	Y_3	Y_4	Y_1	Y_2	Y_3	Y_4
Precision	0,957	0,957	0,948	0,982	0,972	0,991	0,957	0,989	1,49	3,39	0,90	0,71
Recall	0,882	0,926	0,976	0,983	0,908	0,945	0,994	0,992	2,64	1,93	1,78	0,85
ACC	0,967				0,980				1,26			

Таблица 4. Матрица невязок

		без учета $X_{3,20}$				с учетом $X_{3,20}$			
		сетью распознанные подпроцессы				сетью распознанные подпроцессы			
		Y_1	Y_2	Y_3	Y_4	Y_1	Y_2	Y_3	Y_4
действительные подпроцессы	Y_1	67	2	1	6	69	0	0	7
	Y_2	0	451	16	19	1	459	16	10
	Y_3	0	4	320	3	0	1	326	0
	Y_4	3	14	9	1507	1	4	8	1520

Из представленных результатов тестирования модели (см. Табл. 3) видно, что введенный элемент данных $X_{3,20}$ улучшил точность работы модели на 1,26%, и средняя доля точности (ACC) работы модели достигла 0,98. Такая точность работы

модели была достигнута благодаря системному подходу выбора оптимальных конфигураций параметров сети для решаемой задачи.

Соответственно, в работе также предлагается алгоритм обработки данных для прогнозирования прихвата ТИ по времени бурения скважины (см. Рис. 4).



Рис. 4. Алгоритм обработки данных для прогнозирования прихвата ТИ по времени бурения скважины.

В четвертой главе приведены результаты исследования эффективности предложенных моделей прогнозирования прихвата ТИ на примере экспериментальных данных скважины № 72, куст №7, Мегионского нефтяного месторождения, Тюменской области. Как показали экспериментальные результаты, модель прогнозирования прихвата ТИ по глубине ствола скважины, позволила обнаруживать прихваты еще на ранних стадиях строительства скважины, что помогает предпринимать меры по снижению рисков их возникновения. А также, модель прогнозирования прихвата ТИ по времени бурения, позволила обнаруживать признаки предприхватного подпроцесса по времени бурения еще до того как возник прихватный подпроцесс. Кроме того, было установлено, что применение двух моделей, позволит оперативно установить причины возникновения предприхватного подпроцесса, а также уменьшить риски возникновения непредвиденных прихватов, за счет обобщения результатов прогнозирования этих моделей. Следует также отметить, что на примере данной скважины, на ликвидацию возникшего прихвата было потрачено 82 часов времени. Следовательно, эффективность применения предложенных моделей

прогнозирования прихвата ТИ на примере данной скважины заключается в том, что моделями был обнаружен прихват на ранней стадии его возникновения, что позволило бы предпринимать своевременные меры по устранению причины его возникновения, в результате сократив 82 часов (НПВ) на ликвидацию возникшего прихвата.

В **заключении** приведены основные выводы и результаты диссертационной работы.

В **приложении** – прилагаются таблицы, акты о внедрении результатов кандидатской диссертации и копии патентов.

ОБЩИЕ ВЫВОДЫ И ЗАКЛЮЧЕНИЕ

В результате проведенного диссертационного исследования решена научная задача, заключающаяся в создании алгоритмов обработки данных и нейросетевых моделей прогнозирования прихвата технологического инструмента, учитывающие в качестве элементов входных данных ряд существенных факторов прихвата, для обнаружения прихватов на ранних стадиях их возникновения.

В ходе выполнения диссертационной работы получены следующие основные результаты:

1. Предложен метод преобразования элементов данных по глубине ствола скважины, имеющих номинальную шкалу измерения, таких как типы горных пород, компоненты понизителя вязкости, понизителя водоотдачи, ингибирующей и смазывающей добавки, в данные, с относительной шкалой измерения, учитывающие долевые значения этих элементов данных и повышающий информативность входных данных нейронной сети.

2. На основе четырехмодульной нейронной сети, разработана новая модель прогнозирования прихвата технологического инструмента по глубине ствола скважины, учитывающая в качестве элементов входных данных такие данные как типы горных пород, компоненты понизителя вязкости, водоотдачи, ингибирующей и смазывающей добавки. Модель на экспериментальных тестовых данных продемонстрировала точность прогнозирования прихвата с вероятностью 0,96, что более чем на 20% превосходит по точности традиционных методов [16-21]. Кроме того, на основе данной модели предлагается алгоритм обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины, позволяющий поинтервально произвести процедуру прогнозирования прихвата в процессе проектирования и бурения скважины.

3. Для полноты описания всех условий, вызывающих процесс возникновения прихвата, и с целью исключения ложных прогнозов на прихват, для набора данных по времени бурения предложен метод расчёта и учета дополнительного элемента

данных, $X_{3,20}$ – длина технологического инструмента, находящегося в зоне открытого ствола, позволяющая учитывать дополнительный фактор прихвата.

4. Предложен метод декомпозиции данных о процессе возникновения и ликвидации прихвата на четыре подпроцесса, такие как Y_1 – предприхватный подпроцесс, Y_2 – прихватный подпроцесс, Y_3 – послеприхватный подпроцесс и Y_4 – штатный подпроцесс. Предложен ряд критериев распознавания этих подпроцессов из числа причин и признаков возникновения прихватов. А также предложен метод сегментации многомерных временных рядов из набора данных по времени бурения по четырем подпроцессам прихвата, с применением критериев распознавания этих подпроцессов, позволяющий получить обучающую выборку по четырем подпроцессам.

5. На основе шестислойной полносвязанной нейронной сети разработана новая модель прогнозирования прихвата технологического инструмента по времени бурения скважины, учитывающая в качестве элементов входных данных, данные о свойствах, параметрах и режимах бурения, а также тренд изменения значений этих данных за 30 - минутный временной интервал. Это позволило полученной модели быть более чувствительной и универсальной к данным из скважин других месторождений и прогнозировать прихват на экспериментальных тестовых данных с вероятностью 0,98. Кроме того, предлагается алгоритм обработки данных для прогнозирования прихвата по времени бурения скважины, позволяющий сократить время процедуры прогнозирования, а также исключить ложный прогноз в обсаженных интервалах ствола скважины во время спускоподъемных и других технологических операций.

6. Проведено исследование эффективности применения двух моделей прогнозирования на реальных экспериментальных данных. Первая модель успешно обнаруживает типы прихвата по интервалам бурения скважины, на стадии проектирования и в процессе бурения. Вторая модель обнаруживает признаки подпроцесса возникновения прихвата по времени бурения. А также было установлено, что применение двух моделей, позволит оперативно установить причины возникновения предприхватного подпроцесса, а также уменьшить риски возникновения непредвиденных прихватов, за счет обобщения результатов прогнозирования этих моделей.

ПУБЛИКАЦИИ ПО ТЕМЕ ДИССЕРТАЦИИ

Публикации в рецензируемых научных изданиях, рекомендованных ВАК при Минобрнауки России:

1. Кодиров, Ш.Ш. Разработка искусственной нейронной сети для прогнозирования прихватов колонн бурильных труб / Ш.Ш. Кодиров, А.Л. Шестаков // Вестник

ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». – 2019. – Т. 19, № 3. – С. 20-32.

2. Шестаков, А.Л. Прогностическая модель прихвата технологического инструмента в процессе бурения скважины на основе глубокой нейронной сети со скользящим окном / А.Л. Шестаков, Ш.Ш. Кодиров // Приборы. – 2021. – №3 (249). – С. 1-8.
3. Кодиров, Ш.Ш., Шестаков, А.Л. Модель и алгоритм прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе четырехмодульной нейронной сети // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». – 2022. – Т. 22, № 1. – С. 125-138.

Публикации в изданиях, индексируемых Scopus:

4. Qodirov, Sh.Sh. Development of Artificial Neural Network for Predicting Drill Pipe Sticking in Real-Time Well Drilling Process / Sh.Sh. Qodirov, A.L. Shestakov // 2020 Global Smart Industry Conference (GloSIC), Chelyabinsk, Russia. – 2020. – P. 139-144.

Патенты:

5. Способ прогнозирования прихватов бурильных труб : пат. №2735794 Российская Федерация, МПК G06N 3/08 (2006.01) / А.Л. Шестаков (RU), Ш.Ш. Кодиров (TJ) ; ФГАОУ ВО «ЮУрГУ(НИУ)» ; Патентный отдел. – № 2020121477 ; опубли. 09.11.2020, Бюл. № 31.
6. Способ прогнозирования прихватов бурильных труб в процессе бурения скважины в режиме реального времени : пат. №2753289 Рос. Федерация : МПК E21B44/00 G06N3/08 / А.Л. Шестаков (RU), Ш.Ш. Кодиров (TJ) ; ФГАОУ ВО «ЮУрГУ(НИУ)» ; Патентный отдел. – №2020134345/03 ; опубли. 12.08.2021, Бюл. № 23.

Публикации в других изданиях:

7. Кодиров, Ш.Ш. Разработка модели искусственной нейронной сети для прогнозирования прихватов колонн бурильных труб / Ш.Ш. Кодиров, А.Л. Шестаков // Наука и технологии в нефтегазовом деле: сборник тезисов докладов II Международной научно-практической конференции (31 января–01 февраля 2020 г.) / ФГБОУ ВО «Кубанский государственный технологический университет». – Краснодар: ФГБОУ ВО «КубГТУ», – 2020. – С. 31-36.
8. Кодиров, Ш.Ш. Разработка нейросетевой модели для прогнозирования прихватов колонн бурильных труб / Ш.Ш. Кодиров, А.Л. Шестаков // Третий Международный молодежный научно-практический форум «Нефтяная столица». г. Нижневартовск 18-19 февраля 2020г. Сборник материалов. – М.: Центр научно-технических решений (АНО ЦЕНТР), – 2020. – С. 108-113.
9. Кодиров, Ш.Ш. Разработка модели искусственной нейронной сети для диагностирования и прогнозирования состояний колонны бурильных труб на предмет риска возникновения прихватов / Ш.Ш. Кодиров, А.Л. Шестаков //

Доклады конференции XXII Всероссийской научно-технической конференции по неразрушающему контролю и технической диагностике. – М.: Спектр, – 2020. – С. 66–67.

10. Кодиров, Ш.Ш. Разработка модели искусственной нейронной сети для прогнозирования прихватов колонн бурильных труб // Тезисы докладов XVIII Всероссийской конференции-конкурса студентов и аспирантов «Актуальные проблемы недропользования». – СПб.: Санкт-Петербургский горный университет, – 2020. – С. 64-65.
11. Qodirov, Sh.Sh. Development of artificial neural network for predicting drill pipe sticking in the drilling process / Sh.Sh. Qodirov, A.L. Shestakov // Abstract Book of the XII International Youth Scientific and Practical Congress «Oil and Gas Horizons». – Moscow: Publishing Center of the National State University of Oil and Gas «Gubkin University», – 2020. – P.75-76.
12. Qodirov, Sh.Sh. Development of artificial neural network for predicting drillpipe sticking in real-time drilling process / Sh.Sh. Qodirov, A.L. Shestakov // Topical issues of rational use of natural resources: XVI International Forum-Contest of Students and Young Researchers. Scientific Conference Abstracts. – Saint-Petersburg: Saint-Petersburg Mining University, – 2020. – Vol. 1. – P. 96-97.
13. Кодиров, Ш.Ш. Разработка нейросетевой модели прогнозирования прихватов колонн бурильных труб // Молодые – Научкам о Земле: Материалы IX Международной научной конференции молодых ученых «Молодые – Научкам о Земле». В 7-ми томах. – М.: Российский государственный геологоразведочный университет им. С. Орджоникидзе, – 2020. – Т. 4. – С. 201-204.
14. Кодиров, Ш.Ш. Нейросетевая прогностическая модель прихвата технологического инструмента по времени бурения скважины // Тезисы докладов XIX Всероссийской конференции-конкурса студентов и аспирантов «Актуальные проблемы недропользования». – СПб.: Санкт-Петербургский горный университет, – 2021. – Т. 1. – С. 194-196.
15. Qodirov, Sh.Sh. Neural network predictive model of drill tools sticking by time of well drilling / Sh.Sh. Qodirov, A.L. Shestakov // Topical issues of rational use of natural resources: XVII International Forum-Contest of Students and Young Researchers. Scientific Conference Abstracts. – Saint-Petersburg: Saint-Petersburg Mining University, – 2021. – Vol. 1. – P. 74-75.
16. Кодиров, Ш.Ш. Разработка нейросетевой модели распознавания технологической аварий при бурении нефтяных и газовых скважин // Труды 64-й Всероссийской научной конференции МФТИ «Радиотехника и компьютерные технологии». – Москва-Долгопрудный-Жуковский: МФТИ, – 2021. – С. 101-103.