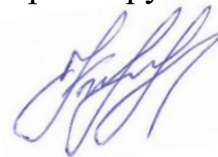


Федеральное государственное автономное образовательное учреждение высшего образования «Южно-Уральский государственный университет (национальный исследовательский университет)»

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

ДИССЕРТАЦИЯ  
на соискание ученой степени  
кандидата технических наук

Научный руководитель:  
доктор технических наук,  
профессор Шестаков А.Л.

Челябинск – 2022

## СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	5
ГЛАВА 1. АНАЛИЗ ПРЕДМЕТНОЙ ОБЛАСТИ ИССЛЕДОВАНИЯ И ПОСТАНОВКА НАУЧНОЙ ЗАДАЧИ .....	15
1.1 Общие положения.....	15
1.2 Состояние вопроса распознавания и прогнозирования прихвата технологического инструмента .....	17
1.2.1 Обзор методов распознавания и прогнозирования прихвата технологического инструмента по глубине ствола скважины .....	18
1.2.2 Обзор методов распознавания и прогнозирования прихвата технологического инструмента по времени бурения скважины .....	24
1.3 Постановка научной задачи исследования .....	33
ГЛАВА 2.        РАЗРАБОТКА        НЕЙРОСЕТЕВОЙ        МОДЕЛИ ПРОГНОЗИРОВАНИЯ        ПРИХВАТА        ТЕХНОЛОГИЧЕСКОГО ИНСТРУМЕНТА ПО ГЛУБИНЕ СТВОЛА СКВАЖИНЫ.....	36
2.1 Классификация прихватов технологического инструмента.....	36
2.2 Анализ методов сбора информации о свойствах, параметрах и режимах бурения .....	38
2.3 Анализ и формирование перечня элементов входных данных по глубине ствола скважины.....	40
2.3.1 Перечень элементов входных данных по глубине ствола скважины	40
2.3.2 Преобразование элементов входных данных.....	42
2.3.3 Классификация набора входных данных по четырем группам.....	46
2.3.4 Методика формирования перечня репрезентативных элементов входных данных по глубине ствола скважины.....	47
2.3.5 Разделение набора данных на тренировочный, проверочный и тестовый мини наборы с последующей нормализацией значений элементов данных.....	52
2.4 Разработка модели прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе полносвязанной нейронной сети.....	54
2.4.1 Искусственные нейронные сети.....	54
2.4.2 Подготовка и настройка гиперпараметров полносвязанной нейронной сети.....	55

2.4.3	Обучение полносвязанной нейронной сети и алгоритм обратного распространения ошибки.....	63
2.4.4	Обобщенная оценка качества работы сети, при различных типах оптимизаторов.....	74
2.5	Разработка модели прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе модульной нейронной сети.....	77
2.5.1	Модульная нейронная сеть.....	77
2.5.2	Структурная регуляризация процесса обучения четырехмодульной нейронной сети.....	79
2.6	Алгоритм обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины в процессе проектирования и бурения скважины .....	83
2.7	ВЫВОДЫ ПО ГЛАВЕ 2.....	86
<b>ГЛАВА 3. РАЗРАБОТКА НЕЙРОСЕТЕВОЙ МОДЕЛИ ПРОГНОЗИРОВАНИЯ ПРИХВАТА ТЕХНОЛОГИЧЕСКОГО ИНСТРУМЕНТА ПО ВРЕМЕНИ БУРЕНИЯ СКВАЖИНЫ .....</b>		<b>88</b>
3.1	Анализ и формирование перечня элементов входных данных по времени бурения скважины.....	88
3.1.1	Перечень элементов входных данных по времени бурения скважины.....	88
3.1.2	Введение дополнительного элемента входных данных.....	89
3.1.3	Декомпозиция данных о процессе возникновения прихвата .....	91
3.1.4	Критерии распознавания подпроцессов прихвата.....	91
3.1.5	Сегментация многомерных временных рядов из набора данных по времени бурения скважины.....	92
3.1.6	Методика формирования перечня репрезентативных элементов входных данных по времени бурения.....	95
3.1.7	Разделение набора данных по времени бурения на тренировочный, проверочный и тестовый мини-наборы с последующей нормализацией значений элементов данных.....	97
3.2	Выбор и обоснование параметров скользящего окна .....	98
3.2.1	Выбор и обоснование глубины прогнозирования.....	100
3.3.	Выбор и обоснование типа и структуры нейронной сети.....	101

3.3.1	Выбор типа нейронной сети.....	101
3.3.2	Обоснование исходной структуры нейронной сети.....	101
3.3.3	Экспериментальный подбор параметров обучения и характеристики сети.....	103
3.4	Алгоритм обработки данных для прогнозирования прихвата технологического инструмента по времени бурения скважины .....	112
3.5	ВЫВОДЫ ПО ГЛАВЕ 3.....	114
ГЛАВА 4. ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ ПРЕДЛОЖЕННЫХ МОДЕЛЕЙ ПРОГНОЗИРОВАНИЯ ПРИХВАТА ТЕХНОЛОГИЧЕСКОГО ИНСТРУМЕНТА.....		116
4.1	Прогнозирование прихвата технологического инструмента по глубине ствола скважины.....	116
4.2	Анализ результатов прогнозирования прихвата технологического инструмента по глубине ствола скважины.....	117
4.3	Прогнозирование прихвата технологического инструмента по времени бурения.....	118
4.4	Анализ результатов прогнозирования прихвата технологического инструмента по времени бурения скважины.....	119
4.5	Обобщение полученных результатов прогнозирования прихвата технологического инструмента.....	124
4.6	ВЫВОДЫ ПО ГЛАВЕ 4.....	125
ОБЩИЕ ВЫВОДЫ И ЗАКЛЮЧЕНИЕ.....		126
БИБЛИОГРАФИЧЕСКИЙ СПИСОК.....		128
ПРИЛОЖЕНИЕ А.....		139
ПРИЛОЖЕНИЕ Б.....		140
ПРИЛОЖЕНИЕ В. Акт о внедрении результатов диссертационного исследования от ООО «РУСГЕОСЕРВИС».....		142
ПРИЛОЖЕНИЕ Г. Акт о внедрении результатов диссертационного исследования от ОАО «НАФТУ ГАЗ».....		143
ПРИЛОЖЕНИЕ Д. Патент на изобретение №2735794.....		144
ПРИЛОЖЕНИЕ Е. Патент на изобретение №2753289.....		145



## ВВЕДЕНИЕ

**Актуальность темы исследования.** Одной из основных целей буровых компаний, во время буровых работ, является минимизация затрат непроизводительного времени, особенно при бурении и строительстве скважины на море, поскольку стоимость буровых работ несколько раз выше, чем на суше [1-15]. 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 промышленные данные [3-15], 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 [2-17].

Доля прихвата составляет от 26% до 60% от общего числа аварий, встречающихся в процессе строительства скважины [1-10, 14, 15]. 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 [3, 10]. Кроме того, из за прихватов происходят значительные экологические ущербы, например при ликвидации прихватов ствол скважины, в том числе не обсаженные интервалы, заполняется нефтью или другими вредными химическими реагентами, которые частично просачиваются в пласты горных пород, и могут даже попасть водоносные горизонты. Соответственно, по выше перечисленным причинам,

прихват является одним из самых тяжелых и затратных видов аварий, встречающихся при буровых работах [1-57, 67-73].

Прихват можно предотвратить, если правильно распознавать начальные условия и признаки-причины их возникновения, и после предпринимать своевременные меры по их предотвращению [3-57]. Однако достоверное распознавание начальных условий и признаков-причины возникновения прихватов – является сложной задачей, поскольку одни и те же условия и признаки в разных ситуациях и операциях могут интерпретироваться по-разному.

Для этого потребуются разработать алгоритмы обработки данных и модели прогнозирования и распознавания прихвата ГИ, 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 [1-57] и является актуальной в научном аспекте и практически значимой.

**Степень научной разработанности темы.** Исследования в области развития и разработки методов распознавания и прогнозирования прихватов рассматривались в трудах отечественных авторов, таких как: Самотой А.К., Аветисов А.Г., Кошелев Н.Н., Аветисян Н.Г., Ахмадуллин М.М., Хлебников С.Р., Абу-Абед Ф.Н., Дмитриевский А.Н., Еремин Н.А., Чащина-Семенова О.К., Фицнер Л.К., Черников А.Д., Сарданашвили О.Н, Столяров В.Е., Архипов А.И. и другие. А также в трудах зарубежных авторов, таких как: Muqeeem M.A., Weekse A.E., Al-Hajji A.A., Al-Dossary A., Abd Elsalam H., ElNady Y., Elfakharany T. Dahab A.S., Abbas R., Gerhard T., Mehran M., Khalil S., Rahman A., Abbas Z., Asad E., Aljubran M.J., Al-Yami A.S., Madan M.A., Alshaikh A.A., Amanullah Md., Alhamed H., Alshaarawi A., Albadran M., Meshari A., Albassam M.K., Al Gharbi S.H., Al-Yami A.S., Skalle P., Aamodt A., Sveen J., Meschi M.R., Shahbazi K., Pordel S.M., Shahbazi K., Shahri M.P., Eren T., Azeez M., Tawfeeq B.A., Hempkins W.B., Kingsborough R.H., Lohec W.E., Nini C.J., Biegler M.W., Kuhn G.R., Howard J.A., Glover S.B., Shoraka S.A.R., Shadizadeh S.R.,

Shahri M.P., Siruvuri C., Nagarakanti S., Miri R., Sampaio J.H.B., Afshar M., Lourenco A., Jahanbakhshi R., Keshavarzi R., Jahanbakhshi R., Murillo A., Neuman J., Samuel R., Heinze L., Al-Baiyat I.A., Chamkalani A., Pordel Shahri M., Poordad S., Morteza E.N., Peyman E., Saeid J., Abbas Ahmed K., Almubarak H., Abbas H., Jawad D., Zhu Q., Wang Z., Jian H., Sadlier A., Says I., Hanson R., Ferreira A.P.L.A., Carvalho D.J.L., Rodrigues R.M., Schnell D.M., Thomson I.J., Baptista R.C., Alves S.B., Salminen K., Cheatham C., Smith M., Valiullin K., Hess J., Alshaikh A., Magana-Mora A., Gharbi S.A., Abdullah A.Y., Ahmed O.S., Aman B.M, Zahrani M.A., Folorunsho I.A., Spivey B., Bailey J., Pokluda J., Coby P., Hang F., Islam A., Zeng H., Chen Z., Zeng Y., Wang X., Siyang L., Nakagawa Y., Inoue T., Bilen H., Mopuri K.R., Miyoshi K., Abe S., Wada R., Kuroda K., Hitoshi T., Konda R.M., Hakan B., Naoki T., Ryota W., Tomoya I., Kazuya K., Tazuru N., Hitoshi T. и другие. Ими предложены множество методов распознавания и прогнозирования прихватов [1-57], в которых применяются самые современные математические аппараты. Однако, в предложенных методах в качестве элементов входных данных, не учитываются ряд важных параметров, описывающих физические условия нахождения ГИ в стволе скважины [36-57], а также ряд факторов влияющих на процессы возникновения прихватов [16-57]. Применяемые перечни также в недостаточной степени описывают условия и процессы возникновения прихватов [10, 16-57]. А также в предложенных методах, получаемые выходные данные обобщенно описывают процессы возникновения прихватов, например, прихват и отсутствие прихвата [16-50]. Такая прогнозная информация не позволяет своевременно обнаруживать причины вызвавшие прихваты, с целью принятия своевременных мер по их предотвращению. Соответственно, все это определяет актуальность темы диссертационной работы, цель и задачи исследования, ее теоретические и методологические основы.

**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.

**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 Pandas, NumPy, Matplotlib, Seaborn, Scikit-learn, а также фреймворка TensorFlow и KERAS.

**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 долевыми 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.

**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.

**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, учитывающий долевые значения этих элементов данных и повышающий 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 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 полученные в работе результаты 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.

**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.).

**Публикации результатов работы.** По материалам диссертационной работы опубликовано 16 работ, в том числе 3 публикаций в изданиях, включенных в перечень ведущих рецензируемых научных журналов и изданий, рекомендованных ВАК Российской Федерации [78, 80, 89], одна статья в рецензируемой зарубежной изданий, индексируемый наукометрической базой Scopus [88]. Получено 2 патента на изобретения [79, 90], копии патентов представлены в приложениях Д и Е.

**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.

**Соответствие паспорту специальности.** Диссертационная работа соответствует паспорту специальности 2.3.1 «Системный анализ, управление и обработка информации, статистика» в следующих областях исследования (пунктах паспорта специальности):

**п. 1:** теоретические основы и методы системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта;

**п. 3:** разработка критериев и моделей описания и оценки эффективности решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта;

**п. 5:** разработка специального математического и алгоритмического обеспечения систем анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта;

**п. 11:** методы и алгоритмы прогнозирования и оценки эффективности, качества, надежности функционирования сложных систем управления и их элементов.

**Реализация результатов исследования.** Полученные результаты диссертационной работы внедрены в деятельности ООО «РУСГЕОСЕРВИС», г. Нижневартовск, Российской Федерации и ОАО «НАФТУ ГАЗ» Республики Таджикистан. А также полученные в работе результаты 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.).

# ГЛАВА 1. АНАЛИЗ ПРЕДМЕТНОЙ ОБЛАСТИ ИССЛЕДОВАНИЯ И ПОСТАНОВКА НАУЧНОЙ ЗАДАЧИ

## 1.1 Общие положения

Строительство скважины всегда сопровождается различными осложнениями и авариями, среди которых самым распространенным и капиталоемким является прихват технологического инструмента (ТИ). Из за прихвата ТИ, нефтегазовые компании ежегодно несут большие финансовые убытки, особенно когда компоновка ТИ состоит из телеметрической системы и забойного двигателя [1-15].

Прихватом при сооружении скважины считается непредвиденная ситуация, характеризующаяся невозможностью извлечения из скважины колонны труб или скважинных приборов, несмотря на способность или неспособность расхаживать их или вращать. Другими словами, пока колонна труб или скважинные приборы не могут быть извлечены из скважины с приложением максимально допустимых с учетом запаса прочности материала нагрузок, они считаются прихваченными [2-17].

Как выше было отмечено, доля прихвата составляет от 26% до 60% от общего числа аварий встречающихся в процессе строительства скважины [1-10, 14, 15]. Аналитические данные показывают, что в 10% случаев, возникшие прихваты удастся ликвидировать более чем за 4 часа, а в 50% случаев, менее чем за 4 часа. Остальные 40% случаев, возникшие прихваты не удастся ликвидировать, вследствие чего, пробуривается новый ствол или скважина ликвидируется (см. Рис. 1.1) [3, 10].



**Рис. 1.1.** Доля ликвидированных и не ликвидированных прихватов в процессе строительства скважины [3, 10].

По механизму и причин возникновения, прихваты классифицируются на три основные группы [2-15]: *дифференциальный прихват; прихват вследствие зашламования или закупоривания кольцевого пространства твердыми частицами; прихват вследствие геометрических изменений ствола скважины.* Во второй главе данной работы (Табл. 2.1) более подробно рассматривается данная классификация, а также механизмы, причины и признаки возникновения каждой группы прихвата.

Прихват может произойти во время бурения, спуско-подъемных операций, каротаже, испытании скважины, проработки ствола скважины или при выполнении других работ, связанных со спуском в скважину съемных частей бурового оборудования.

Прихват можно предотвратить, если по ранним признакам правильно идентифицировать начало возникновения того или иного вида прихвата и предпринимать своевременные меры [1-15, 55], которые в нефтегазовом деле принято называть «предупреждением прихватов». Существует набор методов по предупреждению прихватов, которые обеспечивают безопасность и не требуют больших трудовых или материальных затрат. Однако своевременное обнаружение ранних признаков проявления прихватов – является сложной задачей, поскольку одни и те же признаки в разных ситуациях, условиях и операциях могут интерпретироваться по-разному. Корректная интерпретация признаков прихватов

затруднительна без учета большого набора влияющих факторов, что в полевых условиях в настоящее время не всегда возможно. Соответственно, разработка алгоритмов обработки данных и методов прогнозирования прихватов, учитывающих большую часть влияющих факторов, позволит минимизировать риски возникновения непредвиденных прихватов.

## **1.2 Состояние вопроса распознавания и прогнозирования прихвата технологического инструмента**

По результатам изучения и анализа существующих методов распознавания и прогнозирования прихвата ТИ [1-57], а также научных консультации с крупными специалистами как профессор Робелло Самуел (Хьюстонский университет, США) [26, 29], профессор Ганджумян Рубен Александрович (МГРИ-РГГРУ, г. Москва), профессор Двойников Михаил Владимирович (Санкт-Петербургский горный университет), Степаненко Ярославом Григорьевичем (ОАО «РУСГЕОСЕРВИС»), Кривошеев Николай Вячеславович («ВолгоградНИПИморнефть» ООО «ЛУКОЙЛ-Инжиниринг», г. Волгоград), Закиров Артём Яудатович (ООО «ГАЗПРОМНЕФТЬ НТЦ»), Якунин Сергей Анатольевич (ООО «ТМК-Премиум Сервис»), занимающимся данной проблемой, пришли к выводу, что все существующие методы прогнозирования прихвата ТИ условно классифицируются на две группы методов:

- *методы распознавания и прогнозирования прихвата ТИ по глубине ствола скважины* [16-35], заключающиеся в том, что в методах, в качестве элементов входных данных применяются свойства, параметры и режимы бурения по глубинным интервалам ствола скважины, и выдается прогноз в виде значений вероятности возникновения прихватов также по этим интервалам (Рис. 1.2);

- *методы распознавания и прогнозирования прихвата ТИ по времени бурения скважины* [36-57], заключающиеся в том, что методами учитываются изменения значения параметров и режимов бурения по времени нахождения технологического инструмента в стволе скважины, и выдается прогноз по

времени в виде значений вероятности возникновения прихватов по истечении определенного интервала времени (Рис. 1.2).



**Рис. 1.2.** Классификация методов распознавания и прогнозирования прихвата технологического инструмента.

Следует отметить, что представленная классификация основана на применяемом типе информации, по которой можно оценивать состояние технологического инструмента в стволе скважины на возможные риски возникновения прихватов. Во второй главе данной работы подробно разматываются традиционный и современный методы сбора информации о параметрах скважины и бурения.

### **1.2.1 Обзор методов распознавания и прогнозирования прихвата технологического инструмента по глубине ствола скважины**

Основоположниками разработки процедуры распознавания, прогнозирования и предупреждения прихватов по глубине ствола скважины в СССР являются А.К. Самотой, А.Г. Аветисов, Н.Н. Кошелев, Н.Г. Аветисян, М.М. Ахмадуллин и С.Р. Хлебников. Предложенная разработка основана на методе максимального правдоподобия [16-21]. Данный метод авторы использовали для прогнозирования возникновения трех типов прихват на экспериментальных (промысловых) данных. Авторы утверждают, что предложенная ими метод был испытан на скважинах различных месторождений, и демонстрировал достоверность правильного прогнозирования прихвата с вероятностью от 0,7 до 0,9. Так как во времена СССР данный метод был

единственным методом прогнозирования прихвата, эту методику начали применять в ряд буровых предприятий до распада СССР. Особенностью данного метода является то, что в методе, в качестве элементов входных данных применяется типы горных пород в предполагаемой зоне возникновения прихвата. Недостаток данного метода состоит в том, что применяемые значения некоторых элементов входных данных имеют грубую градацию. Например, если в прогнозируемом интервале ствола скважины имеется несколько типов горных пород, то перечисляются только типы горных пород, и не указываются доли содержаний каждого типа породы в данном интервале. А также сама методика и процедура прогнозирования прихвата весьма трудоемкая.

За рубежом, коллективом ученых (Hempkins, W.B., Kingsborough, R.H., Lohec, W.E., Nini, C.J. [22]; Biegler, M.W., Kuhn, G.R. [23]; Howard, J.A., Glover, S.B. [24]; Shoraka, S.A.R., Shadizadeh, S.R., Shahri, M.P. [25]) был разработан метод прогнозирования прихвата на основе многофакторного дискриминантного анализа. Методом оценивается 28 общих параметров и режимов бурения, среди которых отбирается 20 из них, как значимые параметры для дискриминантной функции. Далее, строится дискриминантная функция и по этой функцией производится классификация на «механический прихват», «дифференциальный прихват» и «отсутствие прихват». По результатам статистической обработки набора данных о прихватах со 137 скважин, строятся графики функции зависимости между риском возникновения прихвата и входными параметрами и режимами бурения. В разработке метода применялись данные о скважинах с прихватами месторождения Мексиканского залива. Несмотря на заявленную точность прогнозирования (с вероятностью 0,81 до 0,87), данная разработка была ограничена в применение в других месторождениях, так как она была приурочена к конкретной месторождений. Недостатком данного метода состоит в том, что в методе, в качестве элементов входных данных, не учитываются тип горных пород в предполагаемой зоне прихвата. Однако, именно данный фактор в большей степени влияет на природу возникновения прихватов, особенно на дифференциальный прихват [2-16, 55].

Коллективом американских и иранских ученых (Siruvuri, C., Nagarakanti, S. & Samuel R. [26], Miri, R., Sampaio, J.H.B., Afshar, M., Lourenco, A. [27] и Jahanbakhshi, R., Keshavarzi, R. [28]) были разработаны методы прогнозирования дифференциального прихвата на основе искусственных нейронных сетей (ИНС). В работе авторов применялись три различные модели ИНС – одномерная свёрточная сеть, многослойный персептрон и радиально базисная сеть. Методы были разработаны с применением экспериментальных данных о дифференциальных прихватах скважин месторождений США и морских месторождений Ирана. Авторы утверждают, что методы прогнозируют дифференциальный прихват с вероятностью 0,90 [26], 0,916 [27] и 0,922 [28]. В качестве элементов входных данных, применяются такие параметры как дифференциальное давление, глубина нахождения технологического инструмента, а также технологические и реологические свойства и параметры бурового раствора. Как выше было отмечено, на природу возникновения дифференциального прихвата больше всего влияют типы горных пород [2-16, 55], залегаемые в интервале открытого ствола и имеющие поверхностный контакт с технологическим инструментом, а также геометрические параметры компоновки низа бурильной колонны [10, 35]. Однако в данных методах, в качестве элементов входных данных, не учитываются эти параметры.

Американскими учеными Хьюстонского университета и компании Халлибертон США (Murillo, A., Neuman, J., Samuel, R. [29]) в 2009 году был разработан метод прогнозирования дифференциального и механического прихвата ТИ на основе адаптивной нечеткой логики и модели нейронной сети, в сочетании с моделью дискриминантного анализа. Исследование проведено на основе экспериментальных производственных данных лаборатории Халлибертон. В качестве входных данных были использованы параметры и режимы бурения, такие как глубина нахождения ТИ, момент вращения на валу ротора или забойного двигателя, давление на стояке бурового насоса, механическая скорость бурения, частота вращения долота, диаметр долота, осевая нагрузка на долото, геометрические характеристики компоновки низа бурильной колонны, а также



свойства и параметры бурового раствора, в том числе реологические. Следует отметить, что значения таких параметров и режимов бурения как момент вращения на валу ротора или забойного двигателя, давление на стояке бурового насоса и механическая скорость бурения по характеру изменчивости по времени (в процессе бурения скважины) имеют динамическую изменчивость. Другими словами, эти параметры и режимы дифференцируемы по времени. Соответственно, по этим параметрам и режимам бурения можно распознавать или прогнозировать прихват, только в том случае, если учитывать тренд изменений значений этих параметров за промежуток времени [55]. В противном случае, распознавать или прогнозировать прихват по этим параметрам и режимам недостоверно. А также в данном методе в качестве элементов входных данных не учитываются типы горных пород в предполагаемой зоне прихвата, хотя механическая скорость бурения скважины мог бы косвенно характеризовать механические свойства пластов горных пород, если учитывалась тренд изменений значений этого параметра за промежуток времени [10, 35]. Авторы заявляют, что разработанная модель на экспериментальных данных распознает прихват с вероятностью 0,98.

На основе экспериментальных данных о прихватах работы [29], авторами (Heinze, L., Al-Baiyat, I.A. [30]) был предложен метод прогнозирования с помощью машинного обучения. В работе рассматриваются две модели, именно искусственные нейронные сети и метод опорных векторов. Авторы утверждают, что метод опорных векторов более надежен, чем искусственные нейронные сети и для его реализации не требуется больших усилий. По утверждениям авторов, метод демонстрировал точность прогнозирования на экспериментальных данных работы [29] с вероятностью 1,0. Однако, следует отметить, что так как модели были обучены на экспериментальных данных работы [29], соответственно, данная работа имеет такие же недостатки, что имелись в работе [29].

В нефтяном технологическом университете Ирана, коллективом ученых (Chamkalani, A., Pordel Shahri, M., Poordad, S. [31]) был разработан метод прогнозирования прихвата ТИ на основе гибридного алгоритма машинного

обучения - машины опорных векторов наименьших квадратов. Отличительной особенностью метода является то, что в качестве элементов входных данных применяется большой перечень свойств, параметров бурового раствора и режимов бурения. В работе авторов отмечено, что метод был испытан на реальных экспериментальных данных со скважин месторождений Ирана и продемонстрировала точность прогнозирования с вероятностью 0,96. В методе в качестве элементов входных данных также как в работе [29] применяются такие параметры и режимы бурения как механическая скорость бурения, частоты вращения долота и расход бурового насоса, и не учитываются типы горных пород в предполагаемой зоне прихвата. Следовательно, данный метод имеет такие же недостатки, которые были отмечены для работах [29, 30].

Американскими и иранскими учеными (Morteza, E.N., Reuman, E., Saeid, J. [32]) предложен метод прогнозирования дифференциального прихвата ТИ с помощью нечеткой логики и активного обучения. В методе, в качестве элементов входных данных, применяются такие параметры и режимы бурения как глубина ствола скважины, динамическое напряжение сдвига бурового раствора (БР), пластическая вязкость БР, статическое напряжение сдвига БР при 1 и 10 мин. в покое, осевая нагрузка на долото и частота вращения долота. Авторы утверждают, что полученная ими модель, по сравнению с существующими моделями [26-29], имеет высокую вероятность (1,0) правильного прогнозирования возникновения дифференциального прихвата. Недостатком данного метода, является то что, в качестве элементов входных данных не учитываются типы горных пород, водоотдача бурового раствора и геометрические параметры компоновки низа бурильной колонны, которые являются важными факторами, влияющие на возникновение дифференциального прихвата [1-16, 35].

Авторами (Abbas, Ahmed K., и др. [33-34]) предложен метод прогнозирования прихвата технологического инструмента с помощью алгоритмов машинного обучения, в частности искусственной нейронной сети и метода опорных векторов. В качестве элементов входных данных применяются технико-технологические свойства, параметры бурового раствора и режимов бурения, а

также литологические характеристики пластов горных пород, в частности типы горных пород. Метод был разработан с использованием экспериментальных данных со скважин месторождений Ирака. Метод может применяться во время операции по спуску и подъему колонны бурильных труб, а также в процессе бурения скважины. Как утверждают авторы, метод на экспериментальных данных демонстрировал точность прогнозирования прихвата с вероятностью 0,90. Недостаток данного метода состоит в том, что в качестве элементов входных данных используются динамические свойства, параметры и режимы бурения без учета временного интервала, то есть не учитывается тренд изменений значений этих параметров за промежуток времени.

В китайской национальной нефтегазовой корпорации (CNPC), авторами (Zhu, Q., Wang, Z., Jian, H. [35]) был предложен метод прогнозирования прихвата ТИ на основе искусственной нейронной сети. В методе, качестве элементов входных данных применяются геологические свойства и параметры скважины, реологические свойства и параметры бурового раствора, а также технико-технологические параметры бурения. В работе очень подробно приводится информация о влиянии геологических и реологических факторов на процесс возникновения прихвата. Но, в свою очередь, в работе не раскрываются параметры модели, в том числе применяемый тип и количество выходной информации, применяемая метрика оценки качества работы модели, а также доля точности работы модели на тестовых экспериментальных данных. Следует также отметить, что в методе, в качестве элементов входных данных применяется большой перечень геологических свойств и параметров, которые на стадии проектирования и бурения новых скважины на недостаточно изученных месторождениях невозможно определить. Другими словами, если скважина бурится впервые на неразведанной площади, то данный метод невозможно применять.

### **1.2.2 Обзор методов распознавания и прогнозирования прихвата технологического инструмента по времени бурения скважины**

Российским исследователем Ф.Н. Абу-Абед предложен метод обнаружения предаварийных ситуаций в процессе промышленного бурения нефтяных скважин [36-40]. В работах автора применяется кластеризация данных, после чего полученные кластеры классифицируются с помощью нейронных сетей. В качестве входного набора данных автором использованы статистические данные об авариях, из библиотеки программного обеспечения станции геолого-технологического исследования. Работа автора охватывает все возможные виды аварий и некоторые осложнения в целом (газонефтеводопроявление и выбросы, поглощения бурового и тампонажного раствора, прихват бурового инструмента, обвал стенок скважины) без детализации причин их возникновения. В качестве выходного сигнала метод выдает два состояния текущей ситуации: «штатная ситуация» и «предаварийная ситуация». Соответственно, такой подход не позволит локализовать прихват, что бы ввести поправки в значениях тех параметров и режимов бурения, которые значительной степени влияют на возникшую предаварийную ситуацию. Следовательно, устранение аварийных ситуаций, в частности прихвата ТИ, на ранних стадиях становится невозможным. Кроме вышесказанного недостатка, необходимо отметить, что так как в методе в качестве элементов входных данных применяются динамические свойства, параметры и режимы бурения, следовало бы учитывать тренд изменений значений этих параметров и режимов за промежуток времени. Иначе, по значениям этих параметров и режимов прогнозировать прихват будет иметь низкую достоверность.

Российскими учеными (Borozdin, S., Dmitrievsky, A., Eremin, N. [41-45]) предложена система для прогнозирования осложнений, в том числе прихвата ТИ на базе искусственной нейронной сети. Предложенная система прогнозирует газонефтеводопроявление, поглощение бурового раствора и прихват колонны бурильных труб буровым шламом. В работе, в качестве элементов входных данных для прогнозирования прихвата применяются такие параметры как

показатель буримости продуктивного пласта, показатель буримости покрышки, траектория ствола скважины и скорость шламакопления. Обучение и тестирование модели искусственной нейронной сети проводится на стимуляционных набор данных полученными по результатам проведения экспериментов по моделированию процесса бурения на тренажере DrillSim – 5000. В работах, авторами приводится точность прогнозирования прихвата ГИ с вероятностью 0,87. К недостаткам данной системы можно отнести следующее: 1) применяемые элементы входных данных не являются измеряемыми параметрами бурения, они являются обобщенными параметрами, которые рассчитываются из множества других параметров бурения с опозданием, то есть рассчитываются после того как пласты были пробурены; 2) прихват вследствие некачественной промывки кольцевого пространства ствола скважины, или именуемое в работе прихват шламом, является одним из 10-12 причин возникновения прихват [1-16]. Следовательно, этого не будет достаточно, что бы минимизировать риски возникновения непредвиденных прихватов; 3) обученная и протестированная модель прогнозирования, может не сработать на реальных производственных данных со скважины, так как она была обучена на стимуляционных данных, которые не все условия реального бурения учитывают.

Сотрудниками американской технологической компанией Baker Hughes Inc. (Sadlier, A., Says, I., Hanson, R.[46] и Ferreira, A.P.L.A., Carvalho, D.J.L., Rodrigues, R.M., Schnell, D.M., Thomson, I.J., Baptista, R.C., Alves, S.B. [47]) была разработана автоматическая система экспертной поддержки и принятия решения. Автоматическая система в процессе бурения скважины в режиме реального времени, анализирует множество параметров и режимов бурения. В случае отклонений, каких либо параметров, система из огромной базы данных ранее пробуренных скважин с аналогичными конфигурациями, подбираются схожие ситуации с рекомендациями по принятию решения. Другими словами, система распознает аварийную ситуацию и предлагает решения на основе ранее удачно принятых решений по возникшей ситуации, то есть оптимизирует процесс принятия решения в предаварийных ситуациях. Недостатки работы состоит в том,

что в трудах авторов не упоминаются про точность обнаружения ситуации, про критерии, по которым производится поиск схожести ситуаций, а также про перечень элементов входных данных, которые анализируются системой. Также, в работах не уточняется как производится сравнения значений свойств, параметров и режимов бурения. Следует отметить, что нормальные значение свойств, параметров и режимов бурения для каждой скважины, с учетом их геологических особенностей, могут быть только свои значений. Соответственно, если произвести сравнение значений свойств, параметров и режимов бурения одной скважины с другой аналогичной скважиной, то только с целью оценки эффективности применяемой техники или технологий бурения. Что касается сравнения с целью обнаружений отклонений, каких либо свойств, параметров и режимов бурения, то это неэффективно и даже недопустимо, так как в бурении скважин не существуют эталонные скважины с эталонными свойствами, параметрами и режимами.

Коллективом ученых (Salminen, K., Cheatham, C., Smith, M., Valiullin, K. [48-49]) был разработан метод прогнозирования на основе двух аналитических моделей, а именно модели анализа отклонении параметров бурения и модели анализа трендов (скорости приращения параметров). Метод заключается в следующем: полученные данные (параметры и режимы бурения) с процесса бурения скважины сравниваются с проектными и архивными данными (параметрами и режимами), в случае значительных отклонений значений параметров и режимов, системой выдается оповещения о высоком уровне риска возникновения прихвата ТИ. Методом учитываются все процессы, протекающие при строительстве скважины, в том числе спуско-подъемные операций, промывка ствола скважины, проработка и проходка забоя скважины. В качестве элементов входных данных в моделях применяются такие параметры и режимы как: глубина нахождения технологического инструмента, скручивающие и осевые нагрузки на бурильную колонну, частота вращения инструмента, нагрузка на крюке талевого блока, давления и расход бурового насоса. Недостаток данного метода состоит в том, что в моделях не учитываются геометрические характеристики технологического инструмента и ствола скважины, например, диаметр долота,

максимальный диаметр КНБК, длина КНБК, угол наклона ствола скважины и т.п. [1-16, 35]. Следовательно, данный метод не может иметь высокую достоверность прогнозирования, так как не учитываются множество важных факторов, по которым можно более точно интерпретировать отклонений или приращений параметров бурения. Также, из экспериментальной части работы [48-49] видно, что данный метод может только обнаруживать (распознавать) процесс возникновения прихвата, но не прогнозировать.

Автором (Joshua Hess [50]) был предложен метод прогнозирования прихвата ТИ на основе линейной регрессионной модели. В регрессионной модели в качестве элементов входных данных учитываются 39 свойств, параметров и режимов бурения, в том числе динамические, которых получают с процесса бурения скважины в режиме реального времени. Недостатком данного метода состоит в том, что в модели в качестве элементов входных данных не учитывается длина технологического инструмента находящейся в зоне открытого ствола, а также тренд изменений значений элементов входных данных из числа динамических свойств, параметров и режимов бурения. Необходимо отметить, что как показывают результаты большого количество экспериментальных исследований [11-13, 16], почти все свойства и параметры бурения и бурового раствора влияют на процесс возникновения прихвата нелинейно. В трудах авторов [11-13, 16] эти нелинейные зависимости приведены, хотя результаты различаются, но все они подтверждают тот факт, что имеются нелинейные зависимости. Следовательно, описывание прихвата линейной регрессионной моделью вызывает сомнение в работоспособности такой модели на данных из скважин других месторождений.

Коллективом ученых национальной нефтяной компании Саудовской Аравии - Saudi Arabian Oil Company были представлены работы посвященными методам распознавания признаков предприхватной ситуации:

- например, в одной работе [10], авторы (Alshaikh, A.A., Albassam, M.K., Al Gharbi, S.H., Al-Yami, A.S.) предлагают метод раннего обнаружения прихвата ТИ на основе обнаружение аномальных трендов значений свойств, параметров и

режимов бурения. В работе авторов, приводится информация о том, что они используют алгоритм машинного обучения для обнаружений признаков предприхватных ситуации. В качестве элементов входных данных они используют такие параметры и режимы бурения как давление на стояке бурового насоса, расход бурового насоса, частота вращения долота, глубина забоя скважины, глубина нахождения инструмента, а также время нахождения технологического инструмента в стволе скважины. В экспериментальной части работы, приведены результаты тестирования метода на примере двух прихватов, возникшие вследствие некачественной промывки ствола скважины. На этих примерах, метод достоверно распознает признаки предприхватной ситуации за 2,5 и 5 часов до возникновения самого прихвата. Следует отметить, что по тем параметрам и режимам, которые используются в качестве элементов входных данных в методе, можно распознавать только те прихваты которые могут возникнуть вследствие некачественной промывки ствола скважины. Результаты экспериментальных исследование, приведенные в работе могут служить подтверждением данного вывода. Соответственно, данный метод имеет ограничения в распознавании или прогнозировании прихватов, возникшие вследствие множество других причин (перечень которых приведены в таблице 2.1, второй главы данного диссертационного исследования);

- в работе [51], авторы (Magana-Mora, A., Gharbi, S., Alshaikh, A., and Abdullah A.Y.) предлагают метод распознавания признаков предприхватной ситуации на основе трех алгоритмов машинного обучения, такие как алгоритм «случайного леса» (Random Forest), «метод опорных векторов» (Support Vector Machine) и «искусственные нейронные сети». Среди них, наилучшие результаты точности распознавания показал алгоритм случайного леса. В методе, в качестве элементов входных данных применяют 13 параметров, в том числе реологические параметры бурового раствора, технологические параметры бурения и геометрические параметры ствола скважины. В методе, учитываются тренды изменений значений всех элементов входных данных, во временном диапазоне до 30 минут. Метод на экспериментальных данных демонстрирует точность



распознавания признаков предприхватной ситуации с вероятностью 0,83. Авторы в следующей своей работе [52], предложили модифицированный метод для улучшения качества обнаружения предприхватной ситуации, за счет применения в модели прогнозирования дополнительных элементов входных данных, рассчитываемые из статистических показателей по времени из уже ранее применяемых элементов входных данных. Например, среднее значение нагрузки на крюке и момента вращения на валу забойного двигателя за 12 временных шагов и т.п. Это позволила методу обнаруживать предприхватные ситуации с вероятностью до 0,92. Недостатком данного метода [51, 52] является то, что в качестве элементов входных данных методом не учитываются такие свойства и параметры как скорость спуско-подъемных операций, длина технологического инструмента в зоне открытого ствола, глубина нахождения технологического инструмента, геометрические параметры технологического инструмента, водоотдача бурового раствора, толщина фильтрационной корки бурового раствора, а также условная вязкость бурового раствора. Перечисленные свойства и параметры являются важными факторами, влияющими на процесс возникновения прихвата, а также являются критериями оценки причин и признаков возникновения прихвата по времени и по глубине ствола скважины (см. Табл. 2.1, во второй главе) [1-16];

- авторами (Ahmed, O.S., Aman, V.M, Zahrani, M.A., Folorunsho, I.A. [53]) была разработана система раннего предупреждения возникновения прихвата ТИ, на основе алгоритмов машинного обучения с применением метода скользящего окна. Система состоит из нескольких подмоделей, именуемые в работе как подмодели обнаружения симптомов отклонения технологических параметров. Данная система прогнозирует прихват на основе взвешенных результатов частоты обнаружения симптомов отклонения технологических параметров бурения. В качестве элементов входных данных в системе используются такие параметры как нагрузка на крюке талевого блока, положения (высота) крюка талевого блока, частота вращения долота, момент вращения на валу ротора или забойного двигателя, давление на стояке бурового насоса, расход бурового насоса,

механическая скорость бурения, осевая нагрузка на долото, глубина нахождения забоя скважины, глубина нахождения долота и углы наклона ствола скважины. Система на экспериментальных данных демонстрировала точность прогнозирования прихвата с вероятностью от 0,67 до 0,80. Необходимо отметить, что как видно из иллюстрации экспериментальной части работы, системой полученные прогнозы о надвигающемся прихвате не достаточно хорошо интерпретируемы. То есть, полученные прогнозы сформулированы в виде нескольких разбросанных точек, по которым сложно понять какие параметры бурения отклонились, и надвигающейся прихват чем был вызван. А также в системе, в качестве элементов входных данных не учитываются реологические свойства и параметры бурового раствора, геометрические параметры технологического инструмента и длина технологического инструмента находящейся в зоне открытого ствола, которые являются важными факторами влияющие на процесс возникновения прихват.

Американскими исследователями (Spivey, B., Bailey, J., Pokluda, J., Coby, P. [54]) был предложен метод мониторинга рисков возникновения прихвата, на основе расчета и анализа введенными авторами индексов прихвата. В работе предлагается рассчитывать индексы статического и динамического прихвата, из трендов значений нагрузки на крюке талевого блока, момента вращения на валу ротора или забойного двигателя и глубины нахождения долота. Далее, по точечным графикам значений этих индексов, которые могут принимать значение от 0 до 100%, производится мониторинг состояние технологического инструмента и его влияние на риски возникновения прихвата. В работе авторов, метод демонстрировал точность совпадение рассчитанных индексов на экспериментальных данных с вероятностью 0,98. Следует отметить, что методом можно только оценивать риски возникновения или уже протекающего прихват, так как метод анализирует признаки происходящего или произошедшего процесса прихвата. Соответственно, данным методом невозможно распознавать признаки предприхватных ситуации, с целью прогнозирования надвигающегося прихвата.

В китайском университете Янцзы, авторами (Zhang, F., Islam, A., Zeng, H., Chen, Z., Zeng, Y., Wang, X., and Siyang, L. [55]) был разработан метод прогнозирования прихвата ТИ на основе гибридной модели, состоящее из четырех подмодели: подмодель переноса шлама по стволу скважины; подмодель крутящего момента на валу ротора или забойного двигателя; и подмодели анализа временных данных процесса бурения. В работе авторов недостаточно широко описан перечень применяемых элементов входных данных. Из имеющегося описания подмодели переноса шлама по стволу скважины и подмодели момента вращения на валу ротора или забойного двигателя, выясняется, что в качестве элементов входных данных применяют такие параметры как расход бурового насоса, механическая скорость бурения, частота вращения долота, диаметры скважины, наружный диаметры бурильных труб, зенитный угол наклона участка ствола скважины и длина технологического инструмента. В методе, в качестве выходной информации гибридной модели, строится диаграмма индекса риска возникновения прихват (SPRI), в которой отображаются графики риска прихвата вследствие некачественной промывки ствола скважины (HCSP) и риска прихвата вследствие других причин (GeSP), в том числе, вследствие геометрических изменений конфигурации ствола скважины. В экспериментальной части работы приводится иллюстрация работы гибридной модели, на примере произошедшего прихвата, который возникнул вследствие некачественной промывки ствола скважины (закупоривание кольцевого пространства ствола скважины выбуренными частичками горной породой). Следует отметить, что приведенные результаты прогнозирования, абсолютно не значимые, например, в диаграмме SPRI, график HCSP по истечением времени бурения меняется почти линейно, хотя в конце временного участка происходит аварийная ситуация с качеством промывки скважины. В свою очередь, график GeSP в конце временного участка реагирует на изменения значений момента вращения на валу ротора (забойного двигателя). Следовательно, абсолютная незначимость результата прогнозирования состоит в том, что прихват произошел по причине некачественной промывки ствола

скважины, но метод не смог это предвидеть раньше, чем когда появились признаки возникновения прихвата и над которыми реагировал график GeSP. То, что на диаграмме SPRI, на график HCSP наблюдается линейный тренд, сложно понять в какой момент времени возникла чрезмерное накопление шлама в стволе скважины. Соответственно, метод хорошо распознает процесс возникновения прихвата, но недостаточно достоверно распознает признаки предприхватных ситуации.

Японскими учеными (Nakagawa, Y., Inoue, T., Bilen, H., Moruri, K.R., Miyoshi, K., Abe, S., Wada, R., Kuroda, K., Hitoshi T. [56-57]) разработана модель прогнозирования предприхватных ситуации, на основе модификации рекуррентной нейронной сети с автоэнкодером (LSTM-AE), которая обучается методом обучения без учителя. В модели, в качестве элементов входных данных применяются 13 параметров бурения, такие как частота вращения долота, момент вращения на валу ротора или забойного двигателя, средняя значения механической скорости бурения, глубина нахождения долота, глубина нахождения забоя скважины, высота (положения) крюка талевого блока, нагрузка на крюке талевого блока, осевая нагрузка на долото, доля поступающего расхода промывочной жидкости из ствола скважины, давление на стояке бурового насоса, ход штока первого и второго бурового насоса. В работах приводятся экспериментальные результаты работы модели, на примере нескольких случаев возникновения прихватов. Как видно из результатов, а также из выводов авторов, только в одном из этих случаев с прихватами модель правильно обнаружил признаки предприхватной ситуации. На примере с дифференциальным прихватом, модель не смогла обнаруживать признаки предприхватной ситуации. Необходимо отметить, что гипотеза и идея, которую авторы исследуют в данной работе, интересные, но, к сожалению, в данной работе они еще не подтверждены. Приведенные экспериментальные результаты не интерпретируемы, даже самим авторам не удастся интерпретировать полученные результаты.

Для удобства, результаты анализа выше рассмотренных методов в обобщенном виде приведены в таблице 1.1 (см. приложение А).

### 1.3 Постановка научной задачи исследования

На основе вышесказанного необходимо отметить, что, несмотря на различие подходов авторов и применение современных алгоритмов машинного обучения, в существующих методах распознавания и прогнозирования прихвата ТИ имеются определенные недостатки. Мы рассматриваем эти недостатки как нереализованные потенциалы в решении рассматриваемой проблемы (прихвата технологического инструмента), которые могут послужить хорошей мотивацией к поиску реализации и исследований этих потенциалов. Например, в методах по глубине ствола скважины перечень элементов входных данных не сформулированы с учетом физико-химических механизмов возникновения прихвата, а также с учетом всех факторов влияющих на процесс возникновения типов прихвата. Как уже известно, большинство из существующих методов распознавания и прогнозирования прихвата ТИ, основаны на алгоритмах машинного обучения, в том числе искусственных нейронных сетях. Но, 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. Это свидетельствует о том, что потенциалы нейронных сетей не реализованы на достаточном уровне. А также ни в одном методе не применялась концепция модульной нейронной сети, которые в решениях аналогичных задач показывают превосходные результаты [58-66], например, в прогнозирование поглощение бурового раствора по глубине ствола скважины, в процессе бурения скважины [58].

Что касается методов распознавания и прогнозирования прихвата ТИ по времени бурения скважины, то в них также, в перечне элементов входных данных не учитываются целые ряды факторов, влияющие на процесс возникновения прихватов. А применяемый перечень элементов входных данных в существующих методах не описывает 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*, когда геомеханические и технологические условия стабильности ствола скважины не нарушены; *предприхватный подпроцесс*, когда нарушаются технологические свойства, параметры и режимы бурения, а также условия стабильности ствола скважины; *прихватный подпроцесс*, когда вследствие нарушений технологических условий бурения и стабильности ствола скважины, интенсивно увеличиваются силы трения между поверхностным контактом стенок скважины и наружным диаметром технологического инструмента; *послеприхватный процесс*, когда вследствие различных мероприятий по ликвидации прихватов происходит интенсивное уменьшение силы трения между поверхностным контактом стенок скважины и наружным диаметром технологического инструмента, и происходит постепенное восстановление беспрепятственного спуска и подъема инструмента.

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.

Отсюда следует вывод, что задача прогнозирования прихвата ТИ с учетом ряда важных факторов, влияющих на процессы их возникновения, а также понимания физических процессов возникновения прихвата, до сих пор не решена в полном объеме. При этом весьма перспективным представляется алгоритмы обработки данных и модели прогнозирования прихвата ТИ по глубине ствола скважины и по времени бурения, на основе искусственной нейронной сети с оптимальными параметрами.

**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.

В соответствии с указанной целью в рамках данной диссертационной работы необходимо решить следующие задачи:

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.

## ГЛАВА 2. РАЗРАБОТКА НЕЙРОСЕТЕВОЙ МОДЕЛИ ПРОГНОЗИРОВАНИЯ ПРИХВАТА ТЕХНОЛОГИЧЕСКОГО ИНСТРУМЕНТА ПО ГЛУБИНЕ СТВОЛА СКВАЖИНЫ

### 2.1 Классификация прихватов технологического инструмента

Как было отмечено, прихватом ТИ при сооружении скважины считается непредвиденный процесс, характеризующийся невозможностью извлечения из скважины колонны бурильных труб с компоновкой низа бурильной колонны (КНБК), с приложением максимально допустимых с учетом запаса прочности материала нагрузок, несмотря на способность или неспособность расхаживать их или вращать [1-16, 67-73].


Прихват ТИ может произойти в процессе бурения, проработки ствола, спускоподъемных операций, шаблонирования ствола, каротаже, или при выполнении других работ, связанных со спуском в скважину съемных частей ТИ [1-16, 67-73].

По механизму и причинам возникновения, прихваты классифицируются на три основные группы: *дифференциальный прихват; прихват вследствие зашламования или закупоривания кольцевого пространства твердыми частицами; прихват вследствие геометрических изменений ствола скважины;*

Два последних, в зарубежной литературе обобщенно называют *механическим прихватом* [2-15, 71-73].

На рисунке 2.1, на основе статистических промысловых данных о прихватах, представлены диаграммы доли распространенности видов прихват [1-16, 67-73], для стран СНГ и дальнего зарубежья.





**Рис. 2.1.** Статистические промысловые данные о доли распространенности видов прихват [1-16, 67-73], I - для стран СНГ, II - для стран дальнего зарубежья: где, а) дифференциальный прихват (под действием перепада давления); б) прихват вследствие геометрических изменений ствола скважины; в) прихват вследствие зашламования или закупоривания кольцевого пространства твердыми частицами (в результате оседания шлама, утяжелителя, осыпей, обвалов, выпучивания пород, сальникообразования и т.п.).

На основе анализа зарубежной и отечественной литературы [1-16, 67-73], составлена таблица классификации прихватов, в зависимости от механизмов, факторов, причин и признаков их возникновения, которая приведена в таблице 2.1 (см. приложение Б).

Следует отметить, что существуют такие понятия как факторы, причины и признаки возникновения прихватов. К факторам относятся существенные обстоятельства или условия, которые влияют на вероятность возникновения процесса прихвата, например прочностные и фильтрационные характеристики залегающих пластов горных пород, геометрические характеристики ствола скважины, реологические и технологические свойства и параметры бурового раствора и т.п. [1-57, 67-73].

К причинам относятся явления или события, вследствие которых возникают прихваты, например длительное удержание технологического инструмента без расхаживания в зоне открытого ствола, внезапное и длительное прекращения промывки ствола скважины во время проходки забоя, применение бурового

раствора с высоким показанием водоотдачи при бурении высокопроницаемых пластов горных пород и т.п. [1-57, 67-73].

Признаками возникновения прихватов, могут служить изменение значения показаний свойств, параметров и режимов бурения по истечении времени, например изменение показаний веса и положения крюка талевого блока, давления и расхода бурового насоса, крутящего момента на валу ротора или забойного двигателя и т.п. Необходимо отметить, что процесс возникновения прихватов можно характеризовать признаками только во время бурения скважины [67-73].

С учетом выше сказанного, обобщенно отметим, следующее: факторы, являются условиями возникновения прихватов, и в зависимости от их сочетания и комбинаций, возникают различные причины возникновения прихватов, которых можно характеризовать признаками.

## **2.2 Анализ методов сбора информации о свойствах, параметрах и режимах бурения**

В процессе строительства скважины, многие технико-технологические и геологические свойства, параметры бурения меняются по мере изменении пространственной положений и глубины ствола скважины. Это связано с тем, что геологические и физические условия ствола скважины неоднородны, и меняются по определенному градиенту. Исходя из этого, в горном и нефтегазовом деле существует традиция сбора информации о параметрах скважин только по глубине ствола скважины [2, 3, 8, 16].

Современные буровые установки для сбора информации и мониторинга процессов в режиме реального времени, оснащены автоматизированными станциями геолого-технологических исследований (ГТИ). Такие станции позволяют не только сопровождать и контролировать все параметры, режимы и процессы, но и заблаговременно сигнализировать об отклонениях каких-либо параметров. Процессом сопровождения бурения скважин занимаются службы ГТИ и геофизических исследований скважин (ГИС) [74-77].

ГТИ являются составной частью геофизических исследований нефтяных и газовых скважин, и предназначены для осуществления контроля за состоянием скважины на всех этапах ее строительства и ввода в эксплуатацию, с целью изучения геологического разреза, достижения высоких технико-экономических показателей бурения [74-77].

ГТИ проводятся непосредственно в процессе бурения скважины и решают комплекс геологических и технологических задач, направленных на оперативное выделение в разрезе бурящейся скважины перспективных на нефть и газ пластов-коллекторов, изучение их фильтрационно-емкостных свойств и характера насыщения, обеспечение безаварийной проводки скважин и оптимизацию режима бурения [74-77].

На буровой, помимо станции ГТИ, параллельно вводится буровой журнал и суточная сводка, где записываются самые важные параметры и режимы бурения, а также все события, которые происходят во время бурения. Запись параметров и режимов осуществляется по интервалам бурения, то есть по глубине ствола скважины, а событие в виде аварии, осложнении, инциденты, прочие случаи, записываются по глубине ствола скважины и по времени их возникновения [74-77].

С учетом выше сказанного, следует отметить следующее:

*- существует информация в виде записи показаний свойств, параметров и режимов бурения по глубине ствола скважины. Соответственно, набор таких данных будем называть набором данных по глубине ствола скважины;*

*- а также существует информация в виде записи показаний свойств, параметров и режимов бурения по времени бурения скважины или по рейсам. Соответственно, набор таких данных будем называть набором данных по времени бурения скважины. В бурении рейсом называется полный цикл спуска и подъема технологического инструмента в стволе скважины. Под термином «по времени бурения скважины» - подразумевается, временной интервал, в течение которого, технологическим инструментом, находившейся в стволе скважины,*

*совершались различные действия и операций, в том числе спуск, бурение, наращивание, проработка, расхаживание, промывка, подъем и т.п.*

### **2.3 Анализ и формирование перечня элементов входных данных по глубине ствола скважины**

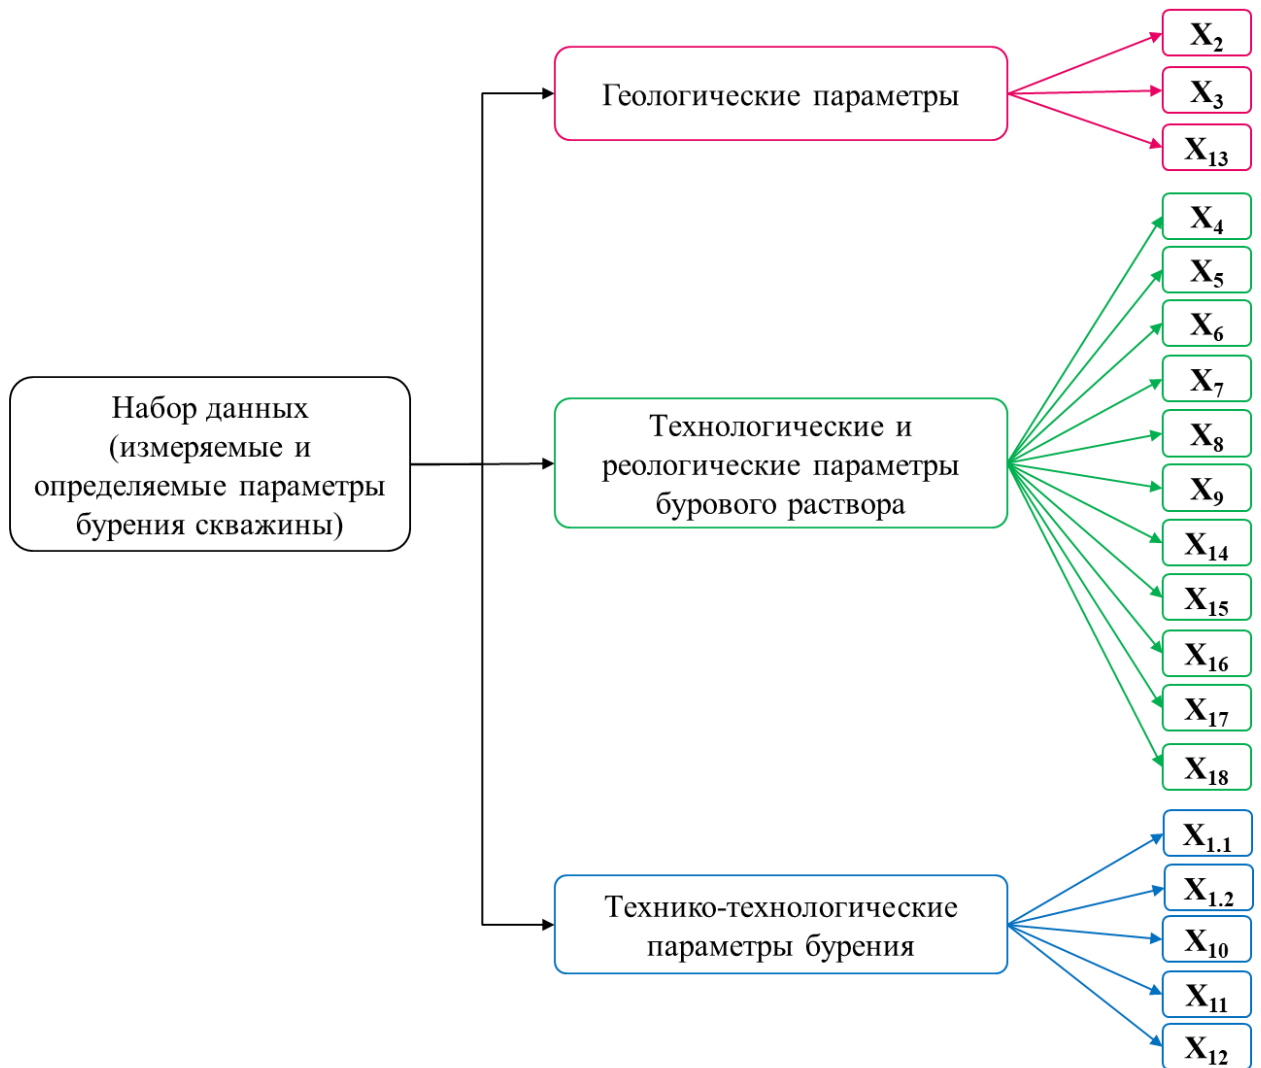
Элементы данных - это наименьшие и неделимые элементарные фрагменты информации, которые представляют собой характеристики исследуемого объекта или процесса. Если исследуемый объект является технологический процесс, то элементами данных этого процесса могут быть свойства, параметры и условия возникновения этого процесса. В математике, особенно в анализе данных, для удобства выполнения операций и действия с данными, элементы данных условно называют переменными и обозначают математическими символами.

#### **2.3.1 Перечень элементов входных данных по глубине ствола скважины**

Перечень элементов входных данных по глубине ствола скважины состоит из следующих параметров бурения, по которым можно оценивать состояния ТИ на возможные риски возникновения прихватов [16-21, 78, 79]:  $X_{1.1}$  – глубина, на которой находится долото в момент прихвата, м;  $X_{1.2}$  – наружный диаметр долота, мм;  $X_2$  – тип горных пород в предполагаемой зоне прихвата;  $X_3$  – пластовое давление в предполагаемой зоне прихвата, кгс/см<sup>2</sup>;  $X_4$  – разность между давлением столба промывочной жидкости и пластовым давлением, в предполагаемой зоне прихвата, кгс/см<sup>2</sup>;  $X_5$  – плотность бурового раствора, г/см<sup>3</sup>;  $X_6$  – условная вязкость, с;  $X_7$  – статическое напряжение сдвига при одной минуты в покое (СНС<sub>1</sub>), мгс/см<sup>2</sup>;  $X_8$  – статическое напряжение сдвига при 10 минут в покое (СНС<sub>10</sub>), мгс/см<sup>2</sup>;  $X_9$  – водоотдача бурового раствора, см<sup>3</sup>/30 мин;  $X_{10}$  – длина компоновки низа бурильной колонны (КНБК), м;  $X_{11}$  – зазор между стенкой скважины и наружным диаметром максимально длинной части КНБК, мм;  $X_{12}$  – зенитный угол участка ствола скважины, градус;  $X_{13}$  – температура на глубине прихвата, °С;  $X_{14}$  – количество нефти в растворе, %;  $X_{15}$  – компоненты понизителя

вязкости;  $X_{16}$  – компоненты понизителя водоотдачи;  $X_{17}$  – компоненты ингибирующей добавки;  $X_{18}$  – компоненты смазывающей добавки.

Эти элементы данных по характеру описаний, условно разделяются на *геологические* ( $X_2, X_3, X_{13}$ ), *технологические и реологические параметры бурового раствора* ( $X_4, X_5, X_6, X_7, X_8, X_9, X_{14}, X_{15}, X_{16}, X_{17}, X_{18}$ ), *техничко-технологические параметры бурения* ( $X_{1.1}, X_{1.2}, X_{10}, X_{11}, X_{12}$ ). А также по степени управляемости условно разделяются на *управляемые* ( $X_6, X_7, X_8, X_9, X_{10}, X_{11}, X_{14}, X_{15}, X_{16}, X_{17}, X_{18}$ ) и *неуправляемые* ( $X_{1.1}, X_{1.2}, X_2, X_3, X_4, X_5, X_{12}, X_{13}$ ) параметры (см. Рис. 2.2) [16-21, 79]. А также по степени изменчивости по времени, они условно считаются статическими [16, 79].



**Рис. 2.2.** Состав перечня элементов входных данных по глубине ствола скважины

[79].

Представленный перечень заимствован из трудов советских ученых [16-21], и мною был дополнен еще одним элементом ( $X_{1,2}$ ). Степень влияние этих элементов на процесс возникновения прихватов подробно рассмотрены в трудах отечественных и зарубежных ученых [1-57, 67-73]. Результаты лабораторных и производственных исследований ученых [1-57, 67-73] подтвердили первостепенное влияние представленного перечня диагностических параметров на возникновение прихватов.

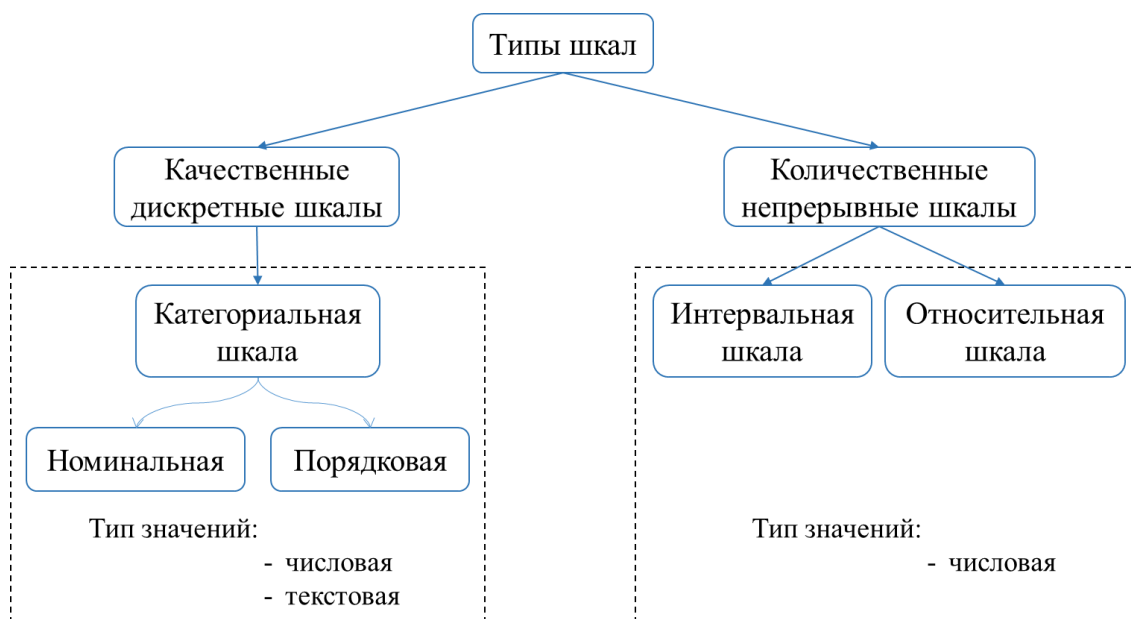
### 2.3.2 Преобразование элементов входных данных

Шкала измерения в статистике – это способ представления переменных и их группировки в различных категориях. Она определяет характер значений, присвоенных переменным в наборе данных [81-86].

Шкала измерений формируется на основе двух ключевых понятий – измерение и масштабирование. Измерение – это процесс записи наблюдений, собранных в рамках исследования. Масштабирование – присвоение объектам числовых или текстовых значений. Эти два понятия, объединенные вместе, образуют связи между объектами и наблюдениями [81-86].

Шкала измерения используется для определения и описания переменных в наборах данных. Она определяет методы, которые могут быть использованы для их анализа. В зависимости от типа анализируемых данных определяется тип шкалы измерения. Выделяют 4 основных видов шкал: номинальная, порядковая, интервальная и относительная. Две первые, обобщенно называют категориальной шкалой [81-86] (см. Рис. 2.3).

Шкалы измерения используются для представления как качественных так и количественных данных. Категориальная шкала используются для измерения качественных данных, в то время как интервальная и относительная используются для измерения количественных.



**Рис. 2.3.** Типы шкал измерения [81-86].

Переменные именуется в соответствие с названием шкалы, которыми они представляются. Например, переменные из категориальной шкалы называются категориальными переменными, переменные из интервальной шкалы, интервальными и т.д.

Категориальные переменные – это данные с ограниченным числом категорий. Категориальные переменные могут иметь текстовые или числовые значения, в которых категории закодированы числовыми кодами. Категориальные переменные могут быть либо номинальные, либо порядковые.

Переменную можно рассматривать как номинальную, когда ее значения представляют классы без естественного упорядочения. Это означает, что данные переменные могут быть измерены только в терминах принадлежности к некоторым, существенно различным классам, при этом не представляется возможность определить количество или упорядочить эти классы [81-86]. Типичным примером может служить переменная  $X_2$  - *тип горных пород в предполагаемой зоне прихвата*, которая может иметь текстовые значения как: глина, аргиллит, песчаник, соль, алевролит, известняк и т.п.

Переменную можно рассматривать как порядковую, когда ее значения представляют классы с некоторым естественным для них упорядочением. Иными

словами, порядковые переменные позволяют ранжировать объекты, указав какие из них в большей или меньшей степени обладают качеством, выраженным данной переменной. Однако они не позволяют утверждать, на сколько больше или на сколько меньше [81-86]. Типичным примером может служить категория горных пород по буримости, которая имеет числовые значения от 1 до 12, где 1 – мягкие породы, 12 – очень твердые породы.

Переменную можно рассматривать как интервальной, когда ее значения упорядочены по уровням, а интервалы между ними равны. Интервальные переменные также можно рассматривать как расширение порядковых переменных. Основным отличием является свойство равных интервалов. Интервальные переменные не только позволяют однозначно определять, какое значение больше или меньше, но и на сколько. Кроме того, в отличие от порядковых и номинальных перемен, с интервальными переменными представляется возможность выполнять арифметические операций [81-86]. Типичным примером является переменная  $X_{13}$  – температура на глубине прихвата, °С.

Что касается относительным переменным, то они очень похожи на интервальные переменные. В дополнение ко всем свойствам интервальных переменных, их характерной чертой является наличие нулевого значения переменной. Типичными примерами являются переменные  $X_{1.1}$  – глубина, на которой находится долото в момент прихвата, м;  $X_5$  – плотность бурового раствора, г/см<sup>3</sup> и т.п. Необходимо отметить, что в большинстве статистических процедур не делается различия между свойствами интервальных и относительных перемен [81-86].

Для повышения информативности и восприимчивости элементов входных данных к нейронным сетям, элементы данных, имеющие текстовые значения из категориальных перемен, необходимо преобразовать в числовые значения этих перемен.

В выше представленном перечне элементов данных, такие данные как:  $X_2$ ,  $X_{15}$ ,  $X_{16}$ ,  $X_{17}$  и  $X_{18}$ , имеют номинальные переменные с тестовыми значениями,



причем имеют различные комбинаций значений нескольких категорий, соответственно, которых необходимо преобразовать.

С учетом существующих подходов преобразования переменных имеющие текстовые значения в числовые [86], для имеющихся переменных  $X_2$ ,  $X_{15}$ ,  $X_{16}$ ,  $X_{17}$  и  $X_{18}$ , предложено преобразование в долевые значения, которая подразумевает разделение элемента данных на несколько субэлементов, с присвоением каждого субэлемента долевое значение в соответствии своего основного элемента (см. Табл. 2.2). Количество субэлемента определяется имеющимся количеством категории в списке элемента имеющее номинальную переменную [78-80]. 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, долевое значение для каждого субэлемента определяется исходя из расчета от основного элемента по всем участвующим категориям.

**Таблица 2.2.** Преобразование элементов входных данных [78-80]

$X_2$ – 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			
$X_{2,1}$	$X_{2,2}$	...	$X_{2,i}$	$X_{15,1}$	$X_{15,2}$	...	$X_{15,j}$	$X_{16,1}$	$X_{16,2}$	...	$X_{16,k}$	$X_{17,1}$	$X_{17,2}$	...	$X_{17,1}$	$X_{18,1}$	$X_{18,2}$	...	$X_{18,m}$
Тип 1, %	Тип 2, %	...	Тип $i$ , %	Компонент 1, %	Компонент 2, %	...	Компонент $j$ , %	Компонент 1, %	Компонент 2, %	...	Компонент $k$ , %	Компонент 1, %	Компонент 2, %	...	Компонент 1, %	Компонент 1, %	Компонент 2, %	...	Компонент $m$ , %

По результатам такого преобразования, образцы имеющийся набора данных о прихватах по глубине ствола скважины будут состоять из 35 элементов данных.

Такое преобразование позволит повысить репрезентативность выборки для нейронной сети и в дальнейшем, улучшить качество ее работы [78-80].

### 2.3.3 Классификация набора входных данных по четырем группам

По результатам индивидуального анализа, с учетом множества влияющих факторов, из числа геологических, технико-технологических свойств и параметров бурения, а также с учетом механизмов и причин возникновения прихват, имеющиеся образцы набора данных, были классифицированы на следующие группы [79]: **I** – группа образцов, в которых происходили дифференциальный прихваты (под действием перепада давления); **II** – группа образцов, в которых происходили прихваты в следствие геометрических изменении ствола скважины; **III** – группа образцов, в которых происходили прихваты, вследствие зашламования или закупоривания кольцевого пространство; **IV** – группа образцов, в условиях которых не происходили прихваты. В четвертую группу (**IV**), были отнесены те образцы набора данных, которые характеризовали состояния ТИ в условиях минимальных или отсутствующих рисков возникновения прихватов. Это группа, была введена для полноты решения задачи, так как на практике бурения, в одних условиях происходят прихваты, а в других не происходят, хотя отличия между этими условиями невелики. Такая классификация позволит полноценно оценить риски возникновения прихватов по всем интервалам бурения.

Соответственно, на основе вышесказанного отметим следующее: так как классификация набора данных на **IV** группы полноценно может указать на всевозможные состояния ТИ, с точки зрения рисков возникновения или отсутствия прихватов [78-80], то в качестве выходной информации о прихватах будем рассматривать в соответствие этим группам, 4 возможных состояния и отметим их целевыми переменными:  $Y_1$  – дифференциальный прихват (под действием перепада давления);  $Y_2$  – прихват в следствие геометрических изменении ствола скважины;  $Y_3$  – прихват, вследствие зашламования или закупоривания кольцевого пространство;  $Y_4$  – отсутствие прихвата.

В задачах классификаций, целевая переменная – это выходная информация, которая указывает о принадлежности к тому или иному классу объекта.

### 2.3.4 Методика формирования перечня репрезентативных элементов входных данных по глубине ствола скважины

В данном параграфе, 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.

*Расчет коэффициента корреляций для набора данных по глубине ствола скважины.* Корреляционный анализ, как правило, используется как вспомогательный инструмент для понимания качества данных. Одним из важных показателей корреляционного анализа является коэффициент корреляции. Этот коэффициент рассчитывается в основном между парами переменных. Под термином «пары переменных» подразумевается – между элементом набора данных –  $X_g$  и целевой переменной –  $Y_q$ .

Существует множество методов расчета коэффициента корреляции, среди которых самыми востребованными и часто применяемыми является метод Пирсона, Спирмена и Кандела. Эти методы имеют ряд определенных ограничений. Например, в методе Пирсона, необходимо, чтобы между испытуемыми парами переменных, из числа элемента выборки и целевой переменной, была линейная зависимость, а также эти переменные должны подчиняться нормальному закону распределения [83, 87].

В свою очередь, метод Спирмена не требует строгих соблюдения нормального закона распределения элементов данных в генеральной совокупности, и линейной зависимости между парами переменных [83, 87]. Именно поэтому данный метод представляет для нас интерес, рассмотрим его поподробнее.

Коэффициент корреляции рангов, предложенный К. Спирменом, относится к непараметрическим показателям связи между парами переменных, измеренными в ранговой шкале. Этот коэффициент определяет степень связи

порядковых переменных, которые в этом случае представляют собой ранги сравниваемых величин [83, 87].

Величина коэффициента корреляции Спирмена также лежит в интервале +1 и -1. Он, как и коэффициент Пирсона, может быть положительным и отрицательным, характеризуя направленность связи между пары переменных, измеренными в ранговой шкале. Ранговый коэффициент корреляции Спирмена подсчитывается по формуле:

$$P = 1 - \frac{6 \cdot \sum D^2}{n \cdot (n^2 - 1)}, \quad (2.1)$$

где  $n$  - количество ранжируемых переменных;  $D$  - разность между рангами по двум переменным для каждого испытуемого;  $\sum D^2$  - сумма квадратов разностей рангов.

При наличии одинаковых рангов формула расчета коэффициента линейной корреляции Спирмена будет несколько иной. В этом случае в формулу вычисления коэффициентов корреляции добавляются два новых члена, учитывающие одинаковые ранги. Они называются поправками на одинаковые ранги и добавляются в числитель расчетной формулы:

$$D_1 = \frac{n^3 - n}{12}, \quad (2.2)$$

$$D_2 = \frac{k^3 - k}{12}, \quad (2.3)$$

где  $n$  - число одинаковых рангов в первом столбце,  $k$  - число одинаковых рангов во втором столбце.

Если имеется две группы одинаковых рангов, в каком-либо столбце то формула поправки несколько усложняется:


$$D_3 = \frac{(n^3 - n) + (k^3 - k)}{12}, \quad (2.4)$$

где  $n$  - число одинаковых рангов в первой группе ранжируемого столбца,  $k$  - число одинаковых рангов во второй группе ранжируемого столбца. Модификация формулы в общем случае такова:


$$P = 1 - \frac{6 \cdot \sum D^2 + D_1 + D_2 + D_3}{n \cdot (n^2 - 1)}. \quad (2.5)$$

Для применения коэффициента корреляции Спирмена, необходимо соблюдать следующие условия: сравниваемые пары переменных должны быть получены в порядковой (ранговой) шкале, но могут быть измерены также в шкале интервалов и отношений; характер распределения коррелируемых величин не имеет значения; число варьирующих образцов выборки в сравниваемых переменных  $X_g$  и  $Y_q$  должно быть одинаковым [83].


Для оценки статистической взаимосвязи между переменными, из числа элементов входных данных и целевой переменной на имеющихся экспериментальных исходных данных о прихватах по глубине ствола скважины произведен расчет коэффициентов корреляции методом Спирмена. Результаты расчетов, в виде корреляционной матрицы представлены на рисунках 2.4 а, 2.4 б и 2.4 в.



**Рис. 2.4 а.** Корреляционная матрица для набора данных о прихватах по глубине ствола скважины, часть 1 [80].



**Рис. 2.4 б.** Корреляционная матрица для набора данных о прихватах по глубине ствола скважины, часть 2 [80].



**Рис. 2.4 в.** Корреляционная матрица для набора данных о прихватах по глубине ствола скважины, часть 3 [80].

Как видно из рисунков, между некоторыми элементами данных и целевыми переменными наблюдается очень слабая корреляция. Но, исключать эти элементы тоже нельзя, так как они неплохо коррелируются с другими целевыми переменными. Известно, что коэффициент корреляции отражает только статистическую характеристику взаимосвязи между парами переменных и эти связи не обязательно должен иметь причинно-следственный характер [83, 87].

Соответственно, на основе полученных корреляционных матриц, по значениям коэффициентов корреляций, все элементы входных данных были

разделены на два списка: репрезентативные и слабо коррелирующие элементы. После этого, с участием слабо коррелирующих элементов входных данных производилось вычисление, для оценки влияния отдельных элементов на качество работы сети которое рассмотрено в следующем разделе данной главы.

***Отбор оптимального перечня репрезентативных элементов входных данных по глубине ствола скважины.*** Задача поиска оптимального подмножества элементов набора входных данных с помощью полного перебора относится к классу трудных и ресурсоемких задач, особенно тогда когда в задачи перебора участвуют более 20 элементов. Однако, существуют различные стратегии и подходы отыскания оптимального подмножества элементов, основанные на эвристиках. Они предполагают, что близким наборам элементов данных соответствуют близкие значения критерия качества распознавания классов.

Одним из оптимальных методов отбора элементов набора данных, являются последовательная оценка, включающая в себя:

- *Последовательное добавление элементов набора данных.* На каждом шаге алгоритм добавляет к текущему набору элементов один элемент данных, из списка слабокоррелирующих элементов, и производится полный цикл обучения, тестирования и оценка модели. Если добавлением элемента данных качество работы модели улучшится, тогда элемент данных считается значимым и оставляется в списке репрезентативных элементов данных, в противном случае считается не значимым и исключается из перечня элементов данных.

- *Последовательное удаление элементов набора данных.* Это «жадная» стратегия поиска, предусматривающая поочередное удаление избыточных элементов данных, из списка слабо коррелирующих элементов данных. Данная стратегия работает по принципу «Последовательного добавления элементов набора данных», только в обратном порядке.

Будем считать, что процесс возникновения прихвата описывается набором элементов данных  $Y_q = \{X_1, X_2, \dots, X_g\}$ . Каждый элемент  $X_g$  – это отображение из  $Y_q$  в некоторое множество  $D_k$  допустимых значений элемента данных из ряда

факторов, в том числе геологических, технико-технологических свойств и параметров бурения, влияющих на процесс возникновения прихвата. Вектор  $X_1(Y_q) \dots X_g(Y_q) \in D_1 \times \dots \times D_k$  - называется факторным описанием объекта  $Y_q$ , который в свою очередь указывает на вероятность принадлежности к  $q$ -тому типу целевой переменной.

Тогда, задача оптимального отбора репрезентативных элементов данных сводится к нахождению такого минимального количества комбинации элементов данных  $X_1(Y_q), X_2(Y_q) \dots X_g(Y_q), g \rightarrow \min$ , при которой значения меры оценки качества работы аппроксимированной функций достигнет максимума:

$$Y_q(x_1, x_2, x_3, \dots x_g) \rightarrow ACC_{max},$$

где, ACC – это одна из метрик оценки точности работы вероятностных функций, которая подробно рассматривается в разделе 2.4 рассматриваемой главы.

В данной работе, слабо коррелирующиеся элементы входных данных подверглись вычислениям с применением выше рассмотренной стратегии отбора элементов входных данных. Анализ результатов вычисления для используемых экспериментальных набора данных показали, что все элементы входных данных имеют весомую значимость на качество работы сети, и их исключать из перечня элементов нецелесообразно.

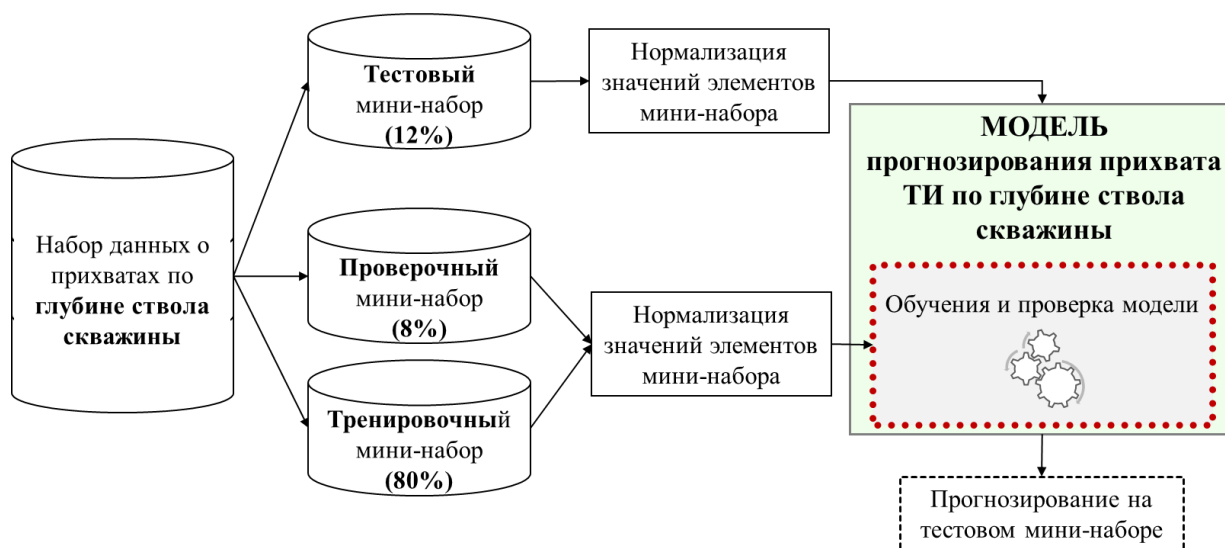
### **2.3.5 Разделение набора данных на тренировочный, проверочный и тестовый мини наборы с последующей нормализацией значений элементов данных**

Прежде чем приступать к этапам разработки модели прогнозирования на нейронных сетях, необходимо имеющейся набор данных о прихватах по глубине ствола скважины разделить на три непересекающиеся мини-наборы: тренировочный, проверочный и тестовый. Это делается для того, чтобы разрабатываемую модель обучить на тренировочном мини-наборе, а процесс обучения модели оценивать на проверочном мини-наборе [93-98]. Соответственно, по завершении процесса обучения модели произвести процедуру тестирования обученной модели на тестовом мини-наборе (см. Рис. 2.5). Такой



подход позволяет получить более точную оценку обобщенности модели [92-98, 78-80, 88-90].

Так как имеющийся набор данных о прихватах по глубине ствола скважины состоит из 167 образцов, то целесообразно разделение произвести в следующих пропорциях: тренировочный мини-набор 80%, проверочный мини-набор 8% и тестовый мини-набор 12% от общего количества образцов в наборе данных [92-97].



**Рис. 2.5.** Схема разделения и применения набора данных о прихватах по глубине ствола скважины [78-80].

**Нормализация значений элементов мини наборов данных.** Для того чтобы значений элементов мини наборов данных были пригодными для передачи в нейронную сеть во всех этапах разработки моделей прогнозирования, необходимо произвести процедуру нормализации. Иными словами, это выполняется для того, что бы сделать сходство разных образцов более заметным для нейронной сети, что помогает модели выделять и обобщать новые данные. Для имеющейся данных о прихватах по глубине ствола скважины, подходит наиболее простая и распространенная форма нормализации [92-101, 78-80, 88-90], суть, которая состоит в центрировании значений элементов данных и масштабирование их по дисперсии этого набора элемента в соответствии с формулой (2.6):

$$X_{\text{норм}g} = \frac{X_g - \bar{X}}{\sigma'}, \quad g = \overline{1, N_0} \quad (2.6)$$

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

## **2.4 Разработка модели прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе полносвязанной нейронной сети**

### **2.4.1 Искусственные нейронные сети**

Искусственные нейронные сети представляют собой технологию, уходящую корнями во множество дисциплин: нейрофизиологию, математику, статистику, физику, компьютерные науки и технику. Они находят свое применение в таких разнородных областях, как моделирование, распознавание образов, обработка изображений, обработка сигналов и управление благодаря одному важному свойству – способности обучаться на основе данных при участии учителя или без учителя [91-101].

Существуют различные типы и модели искусственных нейронных сетей, которые различаются по принимаемым видам входной информации (графической, звуковой, текстовой, цифровой и т.д.), а также методам их обработки [91-101].

По результатам анализа существующей теории о нейронных сетях [91-101] и имеющейся наборов данных о прихватах, в настоящей работе для распознавания и прогнозирования прихвата технологического инструмента используется многослойная нейронная сеть [78-80, 88-90].

Многослойные нейронные сети, условно разделяются на полносвязанные и модульные сети. В полносвязанных нейронных сетях (ПНС), нейроны в слоях имеют последовательное соединение только с нейронами следующего слоя, образуя единый массив полносвязанности между нейронами соседних слоев. В свою очередь, модульные нейронные сети (МНС) состоят из нескольких параллельно соединенных блоков полносвязанных сетей, называемыми

модулями. Выходы этих модулей объединяются блоком полносвязанной сети, называемом интегратором [93-101].

#### 2.4.2 Подготовка и настройка гиперпараметров полносвязанной нейронной сети

Интуитивно гиперпараметры можно представить как параметры, которые не были извлечены из данных и являются «рычагами» управления моделью, т.е. параметры, которые можно изменять с целью улучшения качества работы модели. Фактически именно гиперпараметры определяют конечные значения векторов весовых коэффициентов и смещений. Например, для трехслойной полносвязанной нейронной сети это параметры  $w^{(n)}$ ,  $w^{(p)}$ ,  $w^{(q)}$  и  $b^{(n)}$ ,  $b^{(p)}$ ,  $b^{(q)}$  которые более подробно будут рассмотрены далее. Примерами гиперпараметров являются также [91-103]: количество скрытых слоев  $(l'_1, l'_2, \dots, l'_r)$ ; количество нейронов в скрытых слоях  $(N_1^{(l'_1)}, N_2^{(l'_2)}, \dots, N_s^{(l'_r)})$ ; число итераций градиентного спуска или эпох обучения сети  $(Ep_1, Ep_2, \dots, Ep_u)$ ; тип функции активации; скорость обучения  $(\eta)$ .

Выбор оптимальных гиперпараметров – итерационная задача. Обычно вначале, из условий решаемой задачи и структуре имеющийся наборов данных, берутся исходные значения гиперпараметров. Затем проводится численный эксперимент, и вычисляются значения доли ошибки работы сети. Далее, процесс повторяется снова и снова с последовательным перебором значений гиперпараметров, пока не будут получены оптимальные результаты качество работы сети [92-100].

**Исходная полносвязанная нейронная сеть.** В решаемой задаче, имеющейся 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 [78-80]. Соответственно, 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.

Соответственно, так как решаемая задача относится к мульти-классовой классификации, то в выходном слое целесообразно применять функцию активации мягкого максимума «Softmax» [92-101]. А также в качестве *функции ошибки* использовать категориальную перекрестную энтропию (*categorical cross-entropy*) [92-97], которая описывается уравнением:

$$L_h = - \sum_{q=1}^{N_3} Y_q \log(\hat{Y}_q), \quad (2.7)$$

где  $\hat{Y}_q$  – предсказанное моделью значение целевой переменной;  $Y_q$  – фактическое значение целевой переменной;  $L_h$  – мера ошибки [93],  $N_3$  – количество нейронов в выходном слое сети ( $N_3 = 4$ ). Целевая переменная  $\hat{Y}_q$  представляет собой вектор из  $q = \overline{1, 4}$  элементов, соответствующий истинному полиномиальному распределению вероятности по всем 4-ем группам. Если правильно определена только одна группа, то вектор будет унитарным. Выходные данные сети  $Y_q$  также представляют собой вектор из  $q = \overline{1, 4}$  – элементов, но соответствующий уже предсказанному сетью полиномиальному распределению вероятности. Категориальная перекрестная энтропия оценивает потери путем сравнения этих двух векторов ( $Y_q, \hat{Y}_q$ ). Истоки понятия перекрестной энтропии и выражения для нее лежат в теории информации, но для понимания физического смысла удобно рассматривать их как метод вычисления разности двух распределений [92, 93].

Функция активации (activation function) применяется для того, что бы ограничить амплитуду выходного сигнала нейрона. Эту функцию можно называть функцией сжатия или оператором нелинейного преобразования, которая может использовать различные функции, определяемая в соответствии с решаемой задачей и типом нейронной сети [91-10]. Из множества существующих разновидностей функции активаций в таблице 2.3 приведены самые применяемые из них для нашей задачи [91-101].

Таблица 2.3. Применяемые активационные функции

Название	Уравнение
Сигмоидальная функция (sigmoid)	$\varphi(u) = \frac{1}{1 + e^{-u}} \quad (2.8)$
Гиперболический тангенс (hyperbolic tangent)	$\varphi(u) = \frac{(e^u - e^{-u})}{(e^u + e^{-u})} \quad (2.9)$
Ректификационная функция (ReLU - Rectified Linear Unit)	$\varphi(u) = \begin{cases} 0, & u < 0 \\ u, & u \geq 0 \end{cases} \quad (2.10)$
Функция мягкого максимума (Softmax)	$\varphi(u) = \frac{e^u}{\sum_i e^u} \quad (2.11)$

где  $u$  – взвешенная сумма линейной комбинаций входных воздействий нейрона, часто называемое сумматорной функцией нейрона,  $e$  – константа или число Эйлера.

Далее, необходимо выбрать тип оптимизатора и метрики оценки качества работы сети. Оптимизатор – это механизм, с помощью которого сеть будет обновлять веса межнейронных связей, опираясь на наблюдаемые данные и значений функции ошибки. Оптимизатор также определяет точный способ использования градиента потерь для изменения параметров [91-101].

Существует множество типов оптимизаторов, такие как SGD, RMSProp, Adadelta, Adagrad, Adam и т.п. которые хорошо себя зарекомендовали в решение большинство инженерных задач [92-101]. Но, для каждой задачи оптимальный выбор типа оптимизатора достигается только по результатам численного эксперимента на различных оптимизаторах с оценкой качества работы сети [78-80].

Для исходной сети, в качестве оптимизатора будем использовать «Adam», так как он считается наиболее универсальным среди всех существующих оптимизаторов для большинства задач [92-103]. Но, как выше было отмечено, в дальнейшем необходимо провести ряд экспериментальных вычисления с различными типами оптимизаторов, и по результатам оценки качества работы

сети при различных оптимизаторах, выбрать оптимальный тип из ряда существующих [78-80].


В качестве меры или метрики оценки качества работы сети для мониторинга на этапах обучения и тестирования, выберем меру «Accuracy» (*ACC*), так как имеющиеся исходные данные о прихватах по глубине ствола скважины имеют почти симметричную пропорцию групп образцов данных и считаются сбалансированными. Мера *ACC* описывается следующим выражением [92-96]:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}, \quad (2.12)$$

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 главе подразумевается вероятность правильного прогнозирования с распознаванием видов прихвата.

На основе вышесказанного, представим основные параметры и структуру исходной двухслойной ПНС на рисунке 2.6 и в таблице 2.4.



**Рис. 2.6.** Структурная схема исходной ПНС: двухслойная полносвязанная нейронная сеть.

**Таблица 2.4.** Основные параметры исходной двухслойной ПНС

Перечень параметров	Параметры
Количество входов сети, из числа элементов входных данных	35
Количество нейронов в первом слое	35
Функция активации нейронов первого слоя	ReLU
Количество нейронов в выходном слое	4
Функция активации выходного слоя	Softmax
Тип функции ошибки сети	Категориальная перекрестная энтропия (categorical cross-entropy)
Тип оптимизатора сети	Adam
Мера оценки качество работы сети	Accuracy
Количество эпох обучения сети	150

**Поиск оптимального количества слоев и нейронов в слоях.** Как известно, основным строительным блоком полносвязанной нейронной сети (ПНС) является слой  $(l'_1, l'_2, \dots, l'_r)$  и нейроны в этих слоях  $(N_1^{(l'_1)}, N_2^{(l'_2)}, \dots, N_s^{(l'_r)})$ . Теоретический, чем больше количество слоев и нейронов в слоях, тем выше точности работы сети. Однако, как показывает практика, при слишком большой размерности слоев и нейронов может наступить явление, которое называется переобучением сети, и тогда такая сеть будет имеет плохую обобщающую способность [93]. 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 [93-101]:

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

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

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.

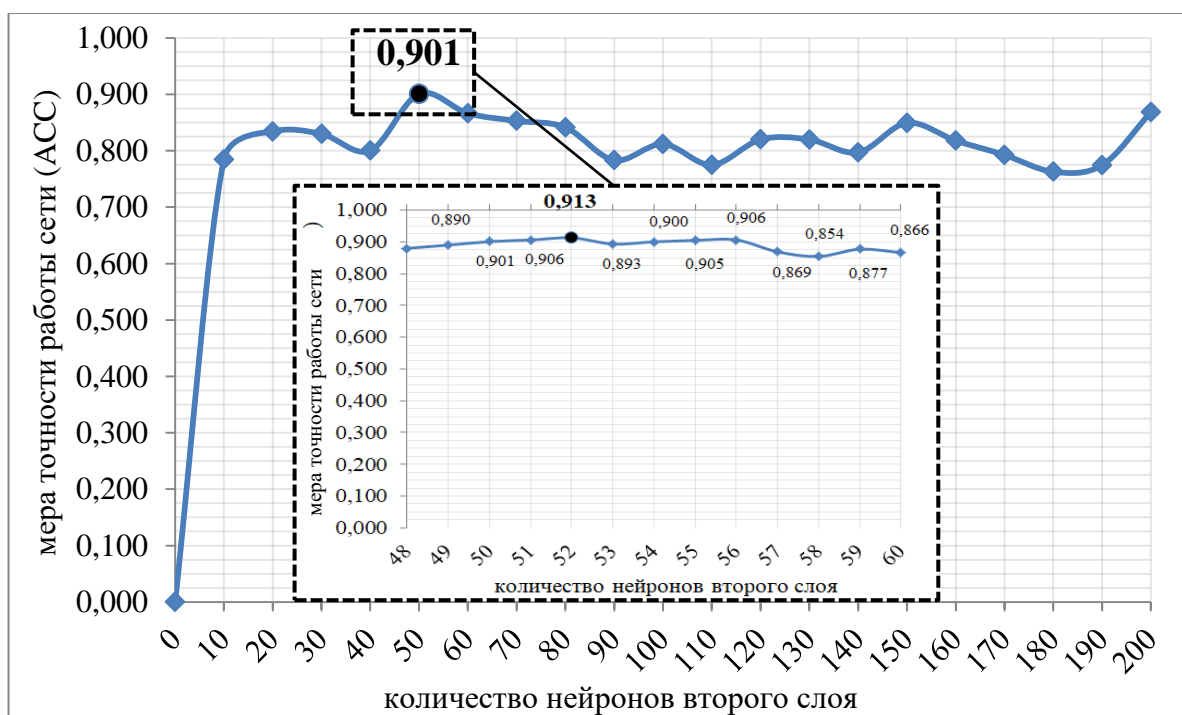
Соответственно, экспериментальные вычисления были проведены следующим образом [78]: добавлялся промежуточный слой в исходную структуру ПНС, и для этого слоя методом последовательного перебора добавлялись нейроны с шагом 10 нейронов. Далее производилась обучения, проверка и тестирование с оценкой качества работы сети. Процедура повторялась с добавлением новых нейронов до тех пор, пока не было достигнута неизменность в значении точности работы сети. После того как было достигнуто то состояние, когда от увеличений количество нейронов качества работы сети не улучшалась, экспериментальные вычисления были приостановлены для данного слоя. Далее, добавлялся новый слой, и процедура повторялась для нового слоя.

Результаты серии вычислительных экспериментов (см. Рис. 2.7) показали, что увеличение количества нейронов входного слоя до 100 приводит к максимальной точности работы сети, а последующее увеличение приводит к нестабильному улучшению точности. С целью нахождения более точного количества нейронов в этом слое, были проведены повторные экспериментальные вычисления, в диапазоне от 92 до 108 нейронов с шагом один нейрон. Результаты показали, что при количестве нейронов 97, точность работы сети достигает максимума (см. Рис. 2.7), следовательно, для выбранной сети оптимальное количество нейронов в первом слое составляет 97. Таким образом, эта процедура проведена для второго слоя (см. Рис. 2.8), и определено оптимальное количество нейронов 52 [78]. Дальнейшие увеличения количество слоев и нейронов в слоях не привели к повышению точности работы сети, а наоборот негативно повлияли.





**Рис. 2.7.** График точности работы сети в зависимости от количества нейронов в первом слое [78].



**Рис. 2.8.** График точности работы сети в зависимости от количества нейронов во втором слое [78].

Исходя из вышесказанного, обоснованно выбрана следующая структура ПНС сети: трехслойная сеть, где первый слой состоит из 97 нейронов, второй из

52 и последний третий (выходной) слой состоит из 4-х нейронов. Во 2-м слое применяется ректификационная функция активации «ReLU», следовательно, на выходном слое применяется функция активации мягкого максимума «Softmax» [78].

**Поиск оптимального количества эпох обучения.** Многослойные нейронные сети, способны создавать коадаптации элементов. «Коадаптация» – термин из нейронауки, означающий ситуацию, при которой связь между двумя элементами становится чрезвычайно сильной за счет ослабления связей между другими элементами. Обычно это приводит к переобучению модели на текущих данных [92-94]. Один из вариантов борьбы с переобучением сети – это ранняя остановка процесса обучения сети. Другими словами, это процедура нахождения оптимального количества эпох (циклов) обучения сети [92-94]. Суть метода заключается в следующем: как ранее отмечалась, для того, что бы обучить, проверить и тестировать сеть, мы разделяли наши данные на тренировочный, проверочные и тестовые мини наборы. На тренировочном мини наборе сеть обучается, а на проверочном мини наборе проверяется качество обучения сети после каждой эпохи обучения (см. Рис. 2.5). Процесс обучения сети отслеживается по двум основным критериям: доля ошибки работы сети на тренировочном мини наборе и доля ошибки работы сети на проверочном мини наборе по прохождению эпох обучения. Далее, строится график зависимости долей ошибки работы сети от эпох обучения, по которой можно заметить, что по мере прохождения эпох обучения сети доля ошибки работы сети на тренировочном мини наборе всегда уменьшается и стремится к нулю, а доля ошибки на проверочном мини наборе в начале уменьшается до определенного минимума, а после начинает возрастать до больших значений [92-100]. Для того, что бы определить оптимальное количество эпох обучения, необходимо выбрать то количество эпох, при которой доля ошибки работы сети на проверочном мини наборе была минимальной. Это та точка минимума значений доли ошибки, после которой наступает процесс переобучения сети [92, 93].

С учетом выше сказанного, постановка задачи поиска оптимальных значений эпох обучения сети будет выглядеть следующим образом: найти такое максимальное значение эпох обучения сети

$$Ep = [Ep_1, Ep_2, \dots, Ep_u] \rightarrow \max,$$

при которой средняя доля ошибки работы сети по всем образцам проверочного мини набора достигает своего минимума

$$L_{n_{val}}^{(Ep)} \rightarrow \min.$$


Следовательно, критерием поиска оптимальных значений эпох обучения будет служить средняя доля ошибки работы сети по всем образцам проверочного мини набора.

С применением алгоритма ранней остановки обучения сети (на английском «early stopping»), которая реализована в библиотеки KERAS, было установлено, что для сети решаемой задачи оптимальное количество эпох обучения равняется 50 [78].

Следовательно, в результате проведенной серии экспериментальных вычислений, наилучшие результаты работы сети были получены при следующих гиперпараметрах [78]: 97 нейронов первого слоя; 52 нейронов второго слоя; 50 эпох обучения. Для удобства дальнейших расчетов, назовем эту сеть итоговой ПНС.

### **2.4.3 Обучение полносвязанной нейронной сети и алгоритм обратного распространения ошибки**

На рисунке 2.9 представлена структура схема итоговой ПНС, состоящая из трех слоев. Как выше было отмечено, в такой сети нейроны одного слоя связаны со всеми нейронами только следующего и предыдущего слоя.



**Рис. 2.9.** Структурная схема итоговой ПНС: трехслойная полностью связанная нейронная сеть.

Математическая модель итоговой трехслойной ПНС описывается следующими уравнениями:

*В первом скрытом слое каждый  $n$  нейрон обладает вектором весовых коэффициентов:*

$$w^{(n,1)} = \left( w_1^{(n,1)}, w_2^{(n,1)}, w_3^{(n,1)}, \dots, w_{N_0}^{(n,1)} \right)^T, \quad n = \overline{1, N_1}$$

где  $w_1^{(n,1)}, w_2^{(n,1)}, w_3^{(n,1)}, \dots, w_{N_0}^{(n,1)}$  – весовые коэффициенты  $n$ -го нейрона для первого, второго, третьего и  $N_0$ -го входного элемента данных по глубине ствола скважины,  $(n, 1)$  – нейрон  $n$  первого слоя,  $N_1$  – количество нейронов в первом скрытом слое ( $N_1 = 97$ ),  $N_0$  – количество подаваемых сети элементов входных данных по глубине ствола скважины ( $N_0 = 35$ ),  $T$  – знак транспонирования.

Взвешенная сумма линейной комбинаций входных воздействий нейрона  $n$  выражается уравнением:

$$u^{(n,1)} = \sum_{g=1}^{N_0} (X_g \cdot w_g^{(n,1)} + b_{N_1}^{(n,1)}), \quad (2.13)$$

где  $X_g$  – это  $g$ -й элемент входных данных по глубине ствола скважины,  $g = \overline{1, N_0}$ ,  $w_g^{(n,1)}$  – весовой коэффициент  $n$ -го нейрона для  $g$ -го входного элемента данных,  $b_{N_1}^{(n,1)}$  – порог или смещение  $n$ -го нейрона.

Тогда выход  $n$  - го нейрона первого скрытого слоя, которая является входом для  $p$  - го нейрона второго скрытого слоя будет:

$$o^{(n,1)} = \varphi^I(u^{(n,1)}),$$

где  $\varphi^I(u^{(n,1)})$  – функция активации  $n$  - го нейрона первого слоя.

Следует отметить, что в начале обучения сети, для каждого слоя нейронов, первоначальные значения весовых коэффициентов инициализируются случайным образом из нормального распределения [92-96]. Предложены различные диапазоны или границы нормального распределения, одним из которых является «Xavier Glorot», которая равна [104]:

для первого слоя

$$w^{(n,1)} = \left[ -\frac{\sqrt{6}}{\sqrt{(N_0 + N_1)}}; \frac{\sqrt{6}}{\sqrt{(N_0 + N_1)}} \right] = [-0,2132; 0,2132],$$

для второго слоя

$$w^{(p,2)} = \left[ -\frac{\sqrt{6}}{\sqrt{(N_1 + N_2)}}; \frac{\sqrt{6}}{\sqrt{(N_1 + N_2)}} \right] = [-0,200; 0,200],$$

и третьего слоя

$$w^{(q,3)} = \left[ -\frac{\sqrt{6}}{\sqrt{(N_2 + N_3)}}; \frac{\sqrt{6}}{\sqrt{(N_2 + N_3)}} \right] = [-0,3273; 0,3273],$$

где  $(n, 1)$  – нейрон  $n$  первого слоя,  $(p, 2)$  – нейрон  $p$  второго слоя,  $(q, 3)$  – нейрон  $q$  третьего слоя,  $N_0$  – количество подаваемых сети элементов входных данных по глубине ствола скважины ( $N_0 = 35$ ),  $N_1$  – количество нейронов в первом скрытом слое ( $N_1 = 97$ ),  $N_2$  – количество нейронов во втором скрытом слое ( $N_2 = 52$ ) и  $N_3$  – количество нейронов в выходном слое, которое, в нашем случае, равно количеству групп в задаче классификации ( $N_3 = 4$ ).

*Соответственно, во втором скрытом слое каждый  $p$  нейрон обладает вектором весовых коэффициентов:*

$$w^{(p,2)} = \left( w_1^{(p,2)}, w_2^{(p,2)}, w_3^{(p,2)}, \dots, w_{N_1}^{(p,2)} \right)^T, \quad p = \overline{1, N_2}$$

где  $w_1^{(p,2)}, w_2^{(p,2)}, w_3^{(p,2)}, \dots, w_{N_1}^{(p,2)}$ , – весовые коэффициенты  $p$ -го нейрона для выходов первого, второго, третьего и  $N_1$ -го нейрона первого скрытого слоя,  $(p, 2)$  – нейрон  $p$  второго слоя,  $N_2$  – количество нейронов во втором скрытом слое ( $N_2 = 52$ ).

Соответственно, выражения для взвешенной суммы линейной комбинаций входных воздействий нейрона  $p$  (второго скрытого слоя) примет вид:

$$u^{(p,2)} = \sum_{n=1}^{N_1} (o^{(n,1)} \cdot w_{N_1}^{(p,2)} + b_{N_2}^{(p,2)}), \quad (2.14)$$

где  $b_{N_2}^{(p,2)}$  - порог для  $p$  - го нейрона, соответственно.

Тогда выход  $p$  - го нейрона второго скрытого слоя, которая является входом для  $q$  - го нейрона третьего слоя будет:

$$o^{(p,2)} = \varphi^{II}(u^{(p,2)}),$$

где  $\varphi^{II}(u^{(p,2)})$  – функция активации  $p$ -го нейрона второго слоя.

*Далее, в выходном (3-ем) слое каждый  $q$  нейрон выходного слоя обладает вектором весовых коэффициентов:*

$$w^{(q,3)} = \left( w_1^{(q,3)}, w_2^{(q,3)}, w_3^{(q,3)}, \dots, w_{N_2}^{(q,3)} \right)^T, \quad q = \overline{1, N_3}$$

где  $w_1^{(q,3)}, w_2^{(q,3)}, w_3^{(q,3)}, \dots, w_{N_2}^{(q,3)}$ , – весовые коэффициенты  $q$ -го нейрона для выходов первого, второго, третьего и  $N_2$ -го нейрона второго скрытого слоя,

$(q, 3)$  – нейрон  $q$  третьего слоя,  $N_3$  – количество нейронов в выходном слое ( $N_3 = 4$ ).

Соответственно, выражения для взвешенной суммы линейной комбинаций входных воздействий нейрона  $q$  примет вид:

$$u^{(q,3)} = \sum_{p=1}^{N_2} (o^{(p,2)} \cdot w_{N_2}^{(q,3)} + b_{N_3}^{(q,3)}), \quad (2.15)$$

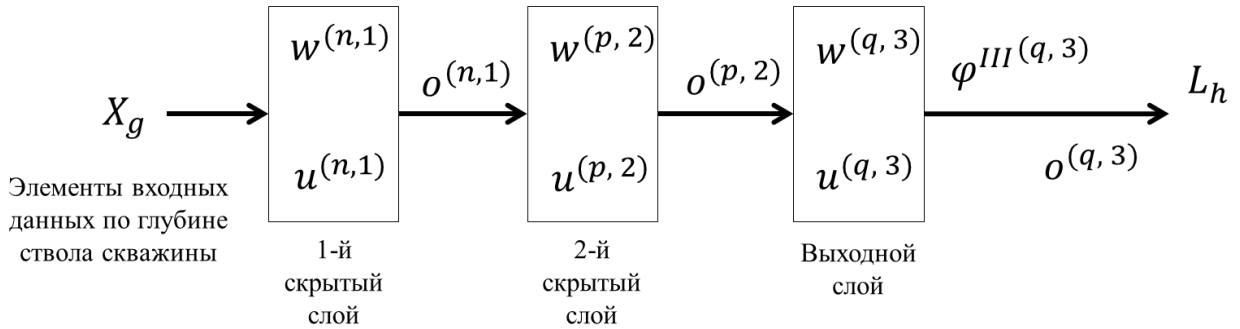
где  $b_{N_3}^{(q,3)}$  - порог для  $q$  - го нейрона, соответственно.

Следовательно, выход  $q$  - го нейрона выходного слоя будет:

$$o^{(q,3)} = \hat{Y}_q = \varphi^{III}(u^{(q,3)}),$$

где  $\varphi^{III}(u^{(q,3)})$  – функция активации  $q$ -го нейрона третьего слоя.

С учетом вышесказанного, а также для удобства дальнейших расчетов, составим упрощенную блок-схему параметров итоговой трехслойной ПНС (см. Рис. 2.10):



**Рис. 2.10.** Упрощенная блок-схема параметров итоговой трехслойной ПНС.

Для осуществления процедуры обучения нейронной сети формируются пары, состоящие из входных векторов, в виде элементов входных данных по глубине ствола скважины  $X_g$  и соответствующих им указаний учителя в виде целевой переменной  $Y_q$ . Далее, производится итерация, где на каждой итерации происходит два прохода сети – прямой и обратный. На прямом, значений элементов входных данных распространяются от входов сети к ее выходам, и формирует собственный выходной образ  $\hat{Y}_q$ . Затем функцией ошибки сравнивается выходной образ с желаемым (целевым) указанием учителя  $Y_q$  и вычисляется доля ошибки работы сети (см. уравнения 2.7). Далее, происходит обратный проход, в которой значения доли ошибки работы сети распространяется от выхода сети к ее входам, и производится коррекция весовых коэффициентов межнейронных связей оптимизатором. Если различий между фактическим и целевым образом нет ( $L_h = 0$ ), то обучение не происходит.

Процесс обучения сети осуществляется минимизацией функции ошибки сети  $L_h$  (см. уравнения 2.7) с помощью настройки весовых коэффициентов межнейронных связей одним из градиентных методов вида [92-102]:

$$w(m') = w(m' - 1) - n' \cdot \text{grad}_{w(m'-1)} \cdot L_h(w(m' - 1)),$$

где  $n'$  – матричный или скалярный шаг алгоритма,  $m'$  – номер шага алгоритма.

*Алгоритм обратного распространения ошибки.* В основе идеи алгоритма лежит использование значений функции ошибки нейронной сети для вычисления величин коррекции весовых коэффициентов межнейронных связей в ее скрытых слоях. Алгоритм является итерационным и использует принципы обучения «по эпохам» (обучение в режиме off-line), когда изменение весовых коэффициентов межнейронных связей производится после подачи на вход сети всех образцов обучающего множества, а ошибка усредняется по всем образцам [92-100].

Вывод алгоритма обратного распространения ошибки строится на основе вычисления градиента функции ошибки  $L_h$  (см. уравнения 2.7).

Для выходного слоя изменение весовых коэффициентов

$$\Delta w^{(q,3)} = w^{(q,3)}(new) - w^{(q,3)}(old)$$

имеет вид

$$\Delta w^{(q,3)} = -\eta \frac{\partial L_h}{\partial w^{(q,3)}}, \quad (2.16)$$

где  $\eta$  – параметр скорости обучения, который позволяет дополнительно управлять величиной шага коррекции  $\Delta w^{(q,3)}$  с целью более точной настройки на минимум ошибки и подбирается экспериментально в процессе обучения (изменяется в интервале от 0 до 1).

Вычисление градиента функции ошибки выполняется по формуле [91, 92, 102]:

$$\frac{\partial L_h}{\partial w^{(q,3)}} = \frac{\partial L_h}{\partial u^{(q,3)}} \frac{\partial u^{(q,3)}}{\partial w^{(q,3)}}. \quad (2.17)$$

Локальный градиент выходного слоя нейрона  $q$  описывается выражением [91, 92, 102]:

$$\delta_q = -\frac{\partial L_h}{\partial u^{(q,3)}}, \quad (2.18)$$

тогда формула (2.17) примет вид

$$\frac{\partial L_h}{\partial w^{(q,3)}} = -\delta_q \frac{\partial u^{(q,3)}}{\partial w^{(q,3)}}.$$

Вектор  $\frac{\partial u^{(q,3)}}{\partial w^{(q,3)}}$  вычисляется по формуле:



$$\frac{\partial u^{(q,3)}}{\partial w^{(q,3)}} = \frac{\partial (w^{(q,3)T} \cdot o^{(p,2)})}{\partial w^{(q,3)}} = o^{(p,2)}, \quad (2.19)$$

следовательно, выражения (2.16) примет вид

$$\Delta w^{(q,3)} = \eta \cdot \delta_q \cdot o^{(p,2)}.$$

Далее, необходимо вычислять локальный градиент выходного слоя нейрона  $q$ :

$$\delta_q = -\frac{\partial L_h}{\partial u^{(q,3)}} = -\frac{\partial L_h}{\partial o^{(q,3)}} \frac{\partial o^{(q,3)}}{\partial u^{(q,3)}}.$$

Из (2.7)  $\frac{\partial L_q}{\partial o^{(q,3)}} = Y_q \log(\hat{Y}_q)$ , а вектор  $\frac{\partial \sigma^{(q,3)}}{\partial u^{(q,3)}} = \varphi^{III}(u^{(q,3)})$ .

В зависимости от вида функции активации выражения  $\varphi^{III}(u^{(q,3)})$  бывают разными. Как выше было отмечено, в решаемой задаче функция активации во выходном слое является мягкий максимум (Softmax, см. уравнения 2.11), что характерна для задачи мульти классовой классификации. Тогда

$$\varphi^{III}(u^{(q,3)}) = o^{(q,3)} = \frac{e^{u^{(q,3)}}}{\sum_q e^{u^{(q,3)}}},$$

следовательно,

$$\varphi^{III}(u^{(q,3)}) = \frac{\partial o^{(q,3)}}{\partial u^{(q,3)}} = \frac{-e^{2u^{(q,3)}}}{(\sum_q e^{u^{(q,3)}})^2} + \frac{e^{u^{(q,3)}}}{\sum_q e^{u^{(q,3)}}} = o^{(q,3)}(1 - o^{(q,3)}),$$

а также с учетом уравнений (2.7), имеем:

$$\begin{aligned} \frac{\partial L_h}{\partial o^{(q,3)}} &= -\sum_q Y_q \frac{\partial \log(\hat{Y}_q)}{\partial o^{(q,3)}} = -\sum_q Y_q \frac{1}{\hat{Y}_q} \frac{\partial \hat{Y}_q}{\partial o^{(q,3)}} = \\ &= -Y_q(1 - \hat{Y}_q) - \sum_q Y_q \frac{1}{\hat{Y}_q} (-\hat{Y}_q) = -Y_q(1 - \hat{Y}_q) + \sum_q Y_q(\hat{Y}_q) = \\ &= -Y_q + Y_q \hat{Y}_q + \sum_q Y_q(\hat{Y}_q) = \hat{Y}_q \left( \sum_q Y_q \right) - Y_q = \hat{Y}_q - Y_q \end{aligned}$$

ИЛИ

$$\frac{\partial L_h}{\partial o^{(q,3)}} = \hat{Y}_q - Y_q = o^{(q,3)} - Y_q.$$

Тогда выражения (2.16) примет вид:

$$\Delta w^{(q,3)} = \eta \cdot \delta_q \cdot o^{(p,2)},$$

где  $\delta_q = o^{(q,3)}(1 - o^{(q,3)})(o^{(q,3)} - Y_q)$ .

*Второй скрытый слой.* Аналогично, процедура вычисления во втором скрытом слое выполняется, как в выходном слое. Обозначим

$$\Delta w^{(p,2)} = -\eta \frac{\partial L_h}{\partial w^{(p,2)}}. \quad (2.20)$$

Выражение  $\frac{\partial L_h}{\partial w^{(p,2)}}$  вычисляется по формуле

$$\frac{\partial L_h}{\partial w^{(p,2)}} = \frac{\partial L_h}{\partial u^{(p,2)}} \frac{\partial u^{(p,2)}}{\partial w^{(p,2)}}, \quad (2.21)$$

так как

$$\frac{\partial u^{(p,2)}}{\partial w^{(p,2)}} = \frac{\partial (w^{(p,2)T} \cdot o^{(n,1)})}{\partial w^{(p,2)}} = o^{(n,1)},$$

если выразить через выражения локального градиента второго скрытого слоя нейрона  $p$ :

$$\delta_p = -\frac{\partial L_h}{\partial u^{(p,2)}}, \quad (2.22)$$

тогда выражения (2.20) примет вид:

$$\Delta w^{(p,2)} = \eta \cdot \delta_p \cdot o^{(n,1)}.$$

Теперь производится вычисление выражения локального градиента для второго скрытого слоя нейрона  $p$ :

$$\delta_p = -\frac{\partial L_h}{\partial u^{(p,2)}} = -\sum_p^{N_3} \frac{\partial L_h}{\partial u^{(q,3)}} \frac{\partial u^{(q,3)}}{\partial o^{(p,2)}} \frac{\partial o^{(p,2)}}{\partial u^{(p,2)}},$$

из (2.18)  $\delta_q = -\frac{\partial L_h}{\partial u^{(q,3)}}$ , и  $\frac{\partial u^{(q,3)}}{\partial o^{(p,2)}} = \frac{\partial (w^{(q,3)T} \cdot o^{(p,2)})}{\partial o^{(p,2)}} = w^{(q,3)}$ .

Так как во втором скрытом слое используется сигмоидальная функция активации (см. уравнения 2.8), то

$$\frac{\partial o^{(p,2)}}{\partial u^{(p,2)}} = \varphi''(u^{(p,2)}) = o^{(p,2)}(1 - o^{(p,2)}).$$

Следовательно, выражения (2.20) примет вид:

$$\Delta w^{(p,2)} = \eta \cdot \delta_p \cdot o^{(n,1)},$$

где

$$\delta_p = o^{(p,2)}(1 - o^{(p,2)}) \sum_q^{N_3} \delta_q w^{(q,3)}.$$

*Первый скрытый слой.* Соответственно, процедура вычисления в первом скрытом слое выполняется, также по аналогии как во втором и выходном слое:

$$\Delta w^{(n,1)} = -\eta \frac{\partial L_h}{\partial w^{(n,1)}}. \quad (2.23)$$

Выражение  $\frac{\partial L_h}{\partial w^{(n,1)}}$  вычисляется по формуле

$$\frac{\partial L_h}{\partial w^{(n,1)}} = \frac{\partial L_h}{\partial u^{(n,1)}} \frac{\partial u^{(n,1)}}{\partial w^{(n,1)}}, \quad (2.24)$$

так как

$$\frac{\partial u^{(n,1)}}{\partial w^{(n,1)}} = \frac{\partial (w^{(n,1)T} \cdot X_{N_0})}{\partial w^{(n,1)}} = X_{N_0}.$$

Выражения локального градиента для первого скрытого слоя нейрона  $n$  выглядит следующим образом:

$$\delta_n = -\frac{\partial L_h}{\partial u^{(n,1)}}, \quad (2.25)$$

тогда получим

$$\Delta w^{(n,1)} = \eta \cdot \delta_n \cdot X_{N_0}.$$

Теперь производится вычисление выражения локального градиента для первого скрытого слоя нейрона  $n$ :

$$\delta_n = -\frac{\partial L_{kh}}{\partial u^{(n,1)}} = -\sum_p^{N_2} \frac{\partial L_h}{\partial u^{(q,3)}} \frac{\partial u^{(q,3)}}{\partial \sigma^{(p,2)}} \frac{\partial \sigma^{(p,2)}}{\partial u^{(p,2)}} \frac{\partial u^{(p,2)}}{\partial \sigma^{(n,1)}} \frac{\partial \sigma^{(n,1)}}{\partial u^{(n,1)}},$$

из выражений (2.18 и 2.22) имеем

$$\begin{aligned} \delta_q &= -\frac{\partial L_h}{\partial u^{(q,3)}}, \text{ и } \frac{\partial u^{(q,3)}}{\partial \sigma^{(p,2)}} = \frac{\partial (w^{(q,3)T} \cdot \sigma^{(p,2)})}{\partial \sigma^{(p,2)}} = w^{(q,3)}, \\ \delta_p &= -\frac{\partial L_h}{\partial u^{(p,2)}}, \text{ и } \frac{\partial u^{(p,2)}}{\partial \sigma^{(n,1)}} = \frac{\partial (w^{(p,2)T} \cdot \sigma^{(n,1)})}{\partial \sigma^{(n,1)}} = w^{(p,2)}. \end{aligned}$$

Так как в первом скрытом слое не используется функция активации, то

$$\frac{\partial o^{(p,2)}}{\partial u^{(p,2)}} = \varphi^I(u^{(n,1)}) = u^{(n,1)}.$$

Следовательно, выражения (2.25) примет вид:

$$\delta_n = (u^{(n,1)}) \sum_p^{N_2} \delta_p w^{(p,2)} \sum_q^{N_3} \delta_q w^{(q,3)}.$$

И так, имеем

$$\Delta w^{(n,1)} = \eta \cdot \delta_n \cdot X_{N_0},$$

$$\delta_n = (u^{(n,1)}) \sum_p^{N_2} \delta_p w^{(p,2)} \sum_q^{N_3} \delta_q w^{(q,3)}.$$

Теперь пошагово опишем алгоритм обратного распространения ошибки [91, 92, 102]:

**Шаг 1:** Присвоить начальные значения величинам  $w^{(n,1)}$ ,  $w^{(p,2)}$ ,  $w^{(q,3)}$ ,  $\eta$ ,  $\varepsilon$ , где  $\varepsilon$  – предельное значение критерия качества для останова процесса обучения.

**Шаг 2:** Подать на нейронную сеть входные сигналы из числа элементов входных данных  $X_{1,1}$ ,  $X_{1,2}$ ,  $X_2$ ,  $X_3$ , ...,  $X_g$ . Задать соответствующий ему желаемый выход  $Y_q$ , вычислить  $o^{(n,1)}$ ,  $o^{(p,2)}$ ,  $o^{(q,3)}$ . Вычислить  $L_h$  и сравнить значение функции ошибки  $L_h$  с предельным значением  $\varepsilon$ . Если  $L_h \leq \varepsilon$ , то процесс обучения завершен, в противном случае перейти к шагу 3.

**Шаг 3:** Вычислить значения локального градиента для выходного слоя нейрона  $q$  по формуле:

$$\delta_q = o^{(q,3)}(1 - o^{(q,3)})(o^{(q,3)} - Y_q).$$

**Шаг 4:** Обновить весовые коэффициенты:

$$\Delta w^{(q,3)} = \eta \cdot \delta_q \cdot o^{(p,2)},$$

$$w^{(q,3)} = w^{(q,3)} + \Delta w^{(q,3)}.$$

**Шаг 5:** Вычислить значения локального градиента для второго скрытого слоя нейрона  $p$  по формуле:

$$\delta_p = o^{(p,2)}(1 - o^{(p,2)}) \sum_q^{N_3} \delta_q w^{(q,3)}.$$

**Шаг 6:** Обновить весовые коэффициенты:

$$\Delta w^{(p,2)} = \eta \cdot \delta_p \cdot o^{(n,1)},$$

$$w^{(p,2)} = w^{(p,2)} + \Delta w^{(p,2)}.$$

**Шаг 7:** Вычислить значения локального градиента для первого скрытого слоя нейрона  $n$  по формуле:

$$\delta_n = (u^{(n,1)}) \sum_p^{N_2} \delta_p w^{(p,2)} \sum_q^{N_3} \delta_q w^{(q,3)}.$$

**Шаг 8:** Обновить весовые коэффициенты:

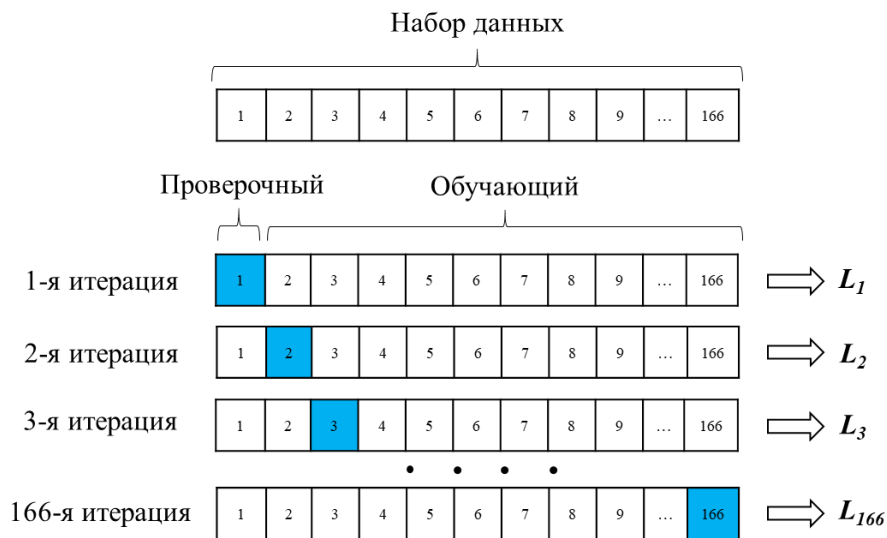
$$\Delta w^{(n,1)} = \eta \cdot \delta_n \cdot X_{N_0},$$

$$w^{(n,1)} = w^{(n,1)} + \Delta w^{(n,1)}.$$

**Шаг 9:** Перейти к шагу 2.

### 2.4.4 Обобщенная оценка качества работы сети, при различных типах оптимизаторов

Оценка качества работы сети проводилась методом кросс-валидации по  $K$ -блокам. Имеющийся набор данных случайным образом подразделялся на 166 - блоков мини данных (см. Рис. 2.11). 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.



**Рис. 2.11.** Структурная схема кросс-валидации по  $K$ -блокам [93-96].

Процедура повторялась 166 - раз, в результате чего, получено 166 моделей с их оценками качества работы сети ( $L_1 \dots L_{166}$ ). Затем вычислялась средняя ошибка работы модели, на основе разных независимых блоков:

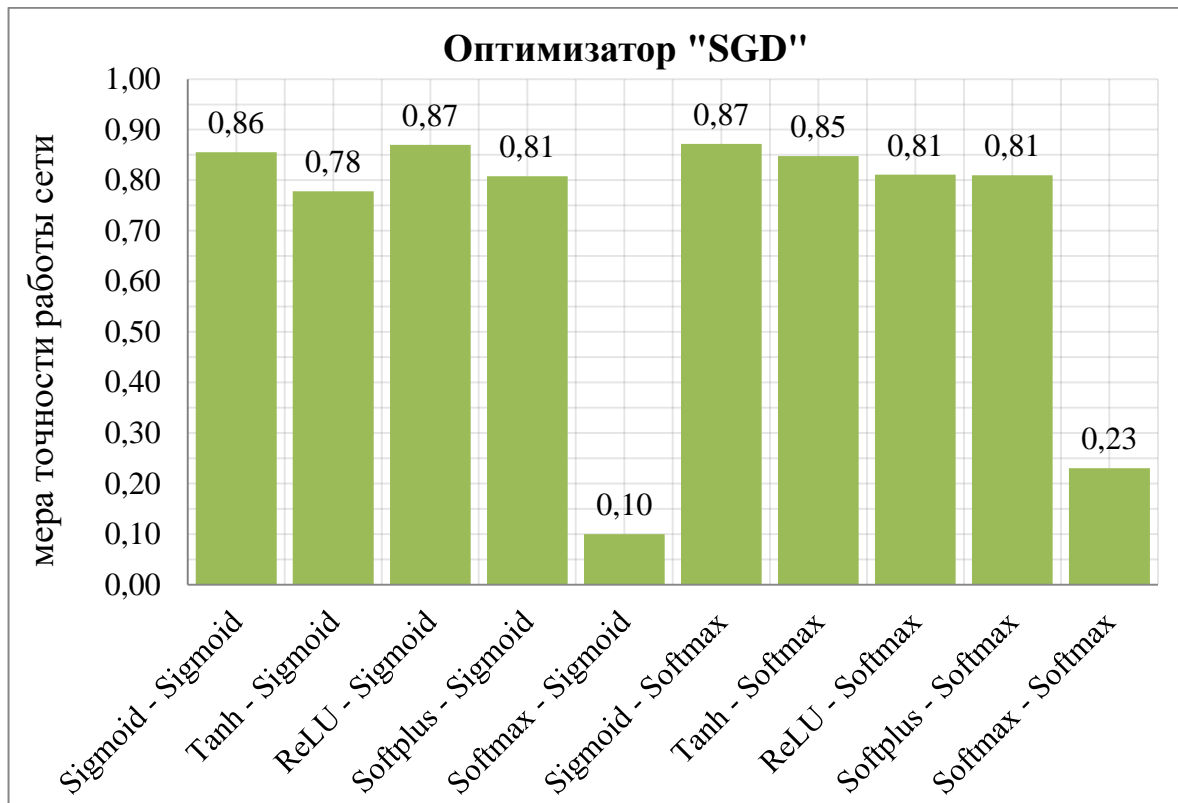
$$L_{\text{mean}} = \frac{1}{166} \sum_{K=1}^{166} L_K. \quad (2.26)$$

Метод кросс-валидации по  $K$ -блокам позволяет нам выполнять тонкие настройки модели, т.е. находить оптимальные значения гиперпараметров, которые дали удовлетворительную обобщающую работоспособность. После того как определены удовлетворительные значения гиперпараметров, повторно произведен процесс обучения модели на полном обучающем наборе. В результате


получена окончательная оценка качества модели на базе независимого тестового набора.

С учетом того, что К - блочная кросс-валидация – это метод генерирования повторных образцов без возврата (непересекающихся образцов). Преимущество этого подхода заключается в том, что каждая точка образца является частью обучающего и проверочного наборов данных ровно один раз, что в итоге позволяет получить более низко дисперсную оценку качества модели [93-100].

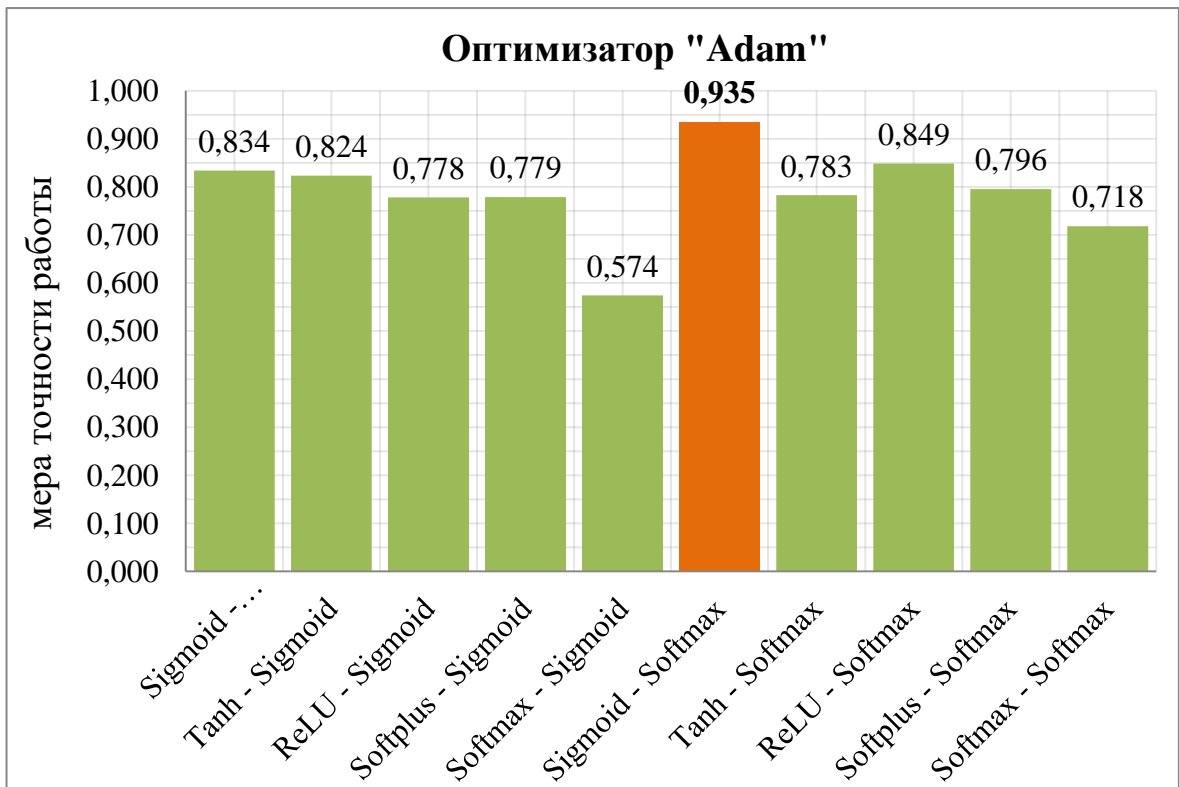
Далее, была произведена серия экспериментальных вычислений с различными оптимизаторами, такими как SGD, Adadelta и Adam, а также с различными комбинациями функции активации второго и выходного слоя сети (см. Рис. 2.12, 2.13 и 2.14) [78].



**Рис. 2.12.** Точность работы сети при различных комбинациях функции активации (скрытого и выходного слоя) с оптимизатором SGD.



**Рис. 2.13.** Точность работы сети при различных комбинациях функции активации (скрытого и выходного слоя) с оптимизатором Adadelata.



**Рис. 2.14.** Точность работы сети при различных комбинациях функции активации (скрытого и выходного слоя) с оптимизатором Adam.



Как видно из полученных результатов серии экспериментальных вычислений (Рис. 2.12, 2.13 и 2.14), максимальная точность работы сети (0,935) достигается при использовании оптимизатора Adam с комбинацией функции активации второго и выходного слоя «Sigmoid-Softmax» (Рис. 2.14) [78]. Соответственно, можно сделать вывод о том, что в решаемой задаче наилучшим типом оптимизатора сети является Adam. А также наилучшая комбинация функции активации нейронов второго и выходного слоя является «Sigmoid-Softmax».

## **2.5 Разработка модели прогнозирования прихвата технологического инструмента по глубине ствола скважины на основе модульной нейронной сети**

### **2.5.1 Модульная нейронная сеть**

Одной из современных тенденций в области нейронных сетей является использование модульных нейронных сетей. Как выше было отмечено, термин «модульная нейронная сеть» подразумевает сеть, состоящую из аналогичных и, в определенной степени, независимых нейронных модулей.

Модульные нейронные сети применяются при решении многих инженерных задач, особенно в задачах классификаций, в большинстве случаев превосходят результаты решения полученные полносвязанными сетями [58-66]. Это связано с тем, что каждый отдельный модуль извлекает свои независимые признаки одного класса из нескольких классов. Таким образом каждый модуль воспроизводит неповторимый другими модулями результат, следовательно объединение выходных сигналов всех модулей в единую сеть позволяет повысить точность работы сети [93, 58-66].

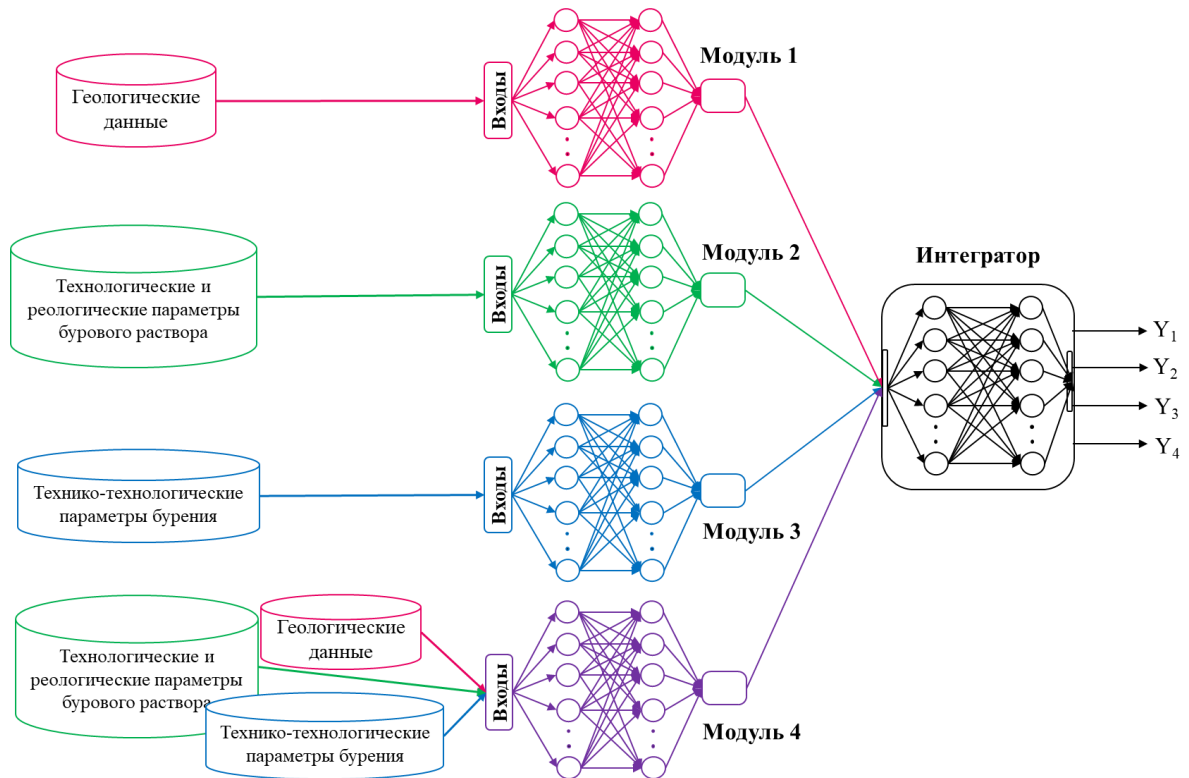
Основной проблемой проектирования модульных нейронных сетей является задача оптимального выбора структуры и топологии нейронной сети, а также правильная организация количества модулей [93]. В данной части работы, в качестве модуля будет использована трехслойная полносвязанная нейронная сеть

с оптимальными параметрами которая рассматривалась в разделе 3.3 данной главы.

Что касается организации количество модулей, то из условия оптимальности организации модульной нейронной сети [93, 58-66] известно, что если на входы каждого модуля подавать одиноковые элементы набора данных и при этом конфигурации модулей идентичный между собой, тогда в процессе обучения сети, каждый модуль будет извлекать одинаковые признаки. То есть, модули будут копировать друг друга, следовательно, смысл модульности сети пропадает, так как результаты работы такой сети ни чем не лучше полносвязанной сети с такими же конфигурациями. Для успешной разработки модульной сети, необходимо что бы на входы каждого модуля поступали различные части элементов набора входных данных (не знакомые другим модулям части элементов данных). В таком случае, результаты работы полученной модульной сети, будут значительно отличаться от результатов работы полносвязанной сети [58-66].

Как было отмечено в начале данной главы, элементы набора данных о прихватах по глубине ствола скважины по характеру описаний условно разделяются на геологические, технологические и реологические параметры бурового раствора, и технико-технологические параметры бурения. Исходя из этого, предложена модульная сеть, состоящее 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 качеству и количеству. 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, в том числе геологические параметры, технологические и реологические параметры бурового раствора, а также технико-технологические параметры бурения. 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. 2.15) [58-66]. Предложенная четырехмодульная нейронная сеть построена по стратегии стек-ансамблирование (stacking ensemble strategies) [93-101].



**Рис. 2.15.** Архитектура четырехмодульной нейронной сети [80].

Так как модульные сети относятся к многослойным персептронам, то соответственно методика обучения и выбора параметров сети идентичны с выше рассмотренной методикой для полносвязанной нейронной сети [91, 92].

### 2.5.2 Структурная регуляризация процесса обучения четырехмодульной нейронной сети

Как выше было отмечено, нейронные сети с большим количеством слоев и нейронов в слоях, способны создавать коадаптации элементов, что приводит к переобучению модели на текущих данных [93-100]. В выше рассмотренной ПНС такое явление как переобучения сети не так сильно проявлялась, так как сеть

имела небольшую емкость (количество слоев и нейронов в слоях). Однако, в рассматриваемой трехмодульной сети, переобучения более сильно проявляется, так как емкость этой сети гораздо больше, чем у трехслойной ПНС.

Еще один из вариантов борьбы с переобучением сети, помимо метода ранней остановки обучения сети, это структурная регуляризация под названием «прореживание» (на английском «dropout»). Во время обучения прореживание на вероятностной основе отбрасывает некоторые межнейронные связи в слоях [91, 92, 105-107].

Вероятностное прореживание межнейронных связей позволяет гарантировать, что никакой конкретный нейрон не окажется в постоянной зависимости от другого конкретного нейрона, благодаря чему модели становятся ошибкоустойчивыми. Прореживание не требует добавления в модель дополнительных параметров, а лишь одного гиперпараметра – «коэффициента прореживания».

Так как структуры и параметры модулей между собой идентичны, рассмотрим математическое выражение вероятностного прореживания межнейронных связей на примере второго и третьего слоя первого модуля [91, 92, 105-107]. Как уже известно, во втором скрытом слое каждый  $p$  нейрон обладает вектором весовых коэффициентов:

$$w^{(p,2)} = \left( w_1^{(p,2)}, w_2^{(p,2)}, w_3^{(p,2)}, \dots, w_{N_1}^{(p,2)} \right)^T, \quad p = \overline{1, N_2}$$

где  $w_1^{(p,2)}, w_2^{(p,2)}, w_3^{(p,2)}, \dots, w_{N_1}^{(p,2)}$ , - весовые коэффициенты  $p$ -го нейрона для выходов первого, второго, третьего и  $N_1$  - го нейрона первого скрытого слоя,  $(p, 2)$  – нейрон  $p$  второго слоя,  $N_2$  – количество нейронов во втором скрытом слое ( $N_2 = 52$ ) первого модуля,  $T$  – знак транспонирования.

Так как хотим описать ситуацию, которая имеет два исхода событий, обозначим  $r$  – как случайную величину, которая имеет распределение Бернулли  $r = \sim \text{Bernoulli}(P)$ , и может принимать всего два значения: 0 и 1 с вероятностью  $P$  и  $Q \equiv 1 - P$  соответственно [105-107]. Таким образом:

$$r = 0 \text{ (межнейронная связь прорежана), с вероятностью } P;$$

$r = 1$  (межнейронная связь непроражена), с вероятностью  $Q$ .

Соответственно,  $P$  – это коэффициент прореживания, который означает вероятность, при которой прореживаются межнейронные связи, обычно выбирается в диапазоне от 0,1 до 0,5 [105-107].

Тогда, если обозначим случайную величину  $r^{(p,2)}$  для второго слоя первого модуля, то выражения для взвешенной суммы линейной комбинаций входных воздействий нейрона  $p$  (второго скрытого слоя) примет вид:

$$u^{(p,2)} = \sum_{n=1}^{N_1} (o^{(n,1)} \cdot r^{(p,2)} \cdot w_{N_1}^{(p,2)} + b_{N_2}^{(p,2)}), \quad (2.27)$$

где  $o^{(n,1)}$  – выход  $n$ -го нейрона первого скрытого слоя, которая является входом для  $p$ -го нейрона второго слоя;  $b_{N_2}^{(p,2)}$  – порог для  $p$ -го нейрона.

Следовательно, выход  $p$ -го нейрона второго скрытого слоя первого модуля, которая является входом для  $q$ -го нейрона третьего слоя будет:

$$o^{(p,2)} = \varphi^{II}(u^{(p,2)}),$$

где  $\varphi^{II}(u^{(p,2)})$  – функция активации  $p$ -го нейрона второго скрытого слоя первого модуля.

Далее, в выходном (3-ем) слое первого модуля каждый  $q$  нейрон выходного слоя обладает вектором весовых коэффициентов:

$$w^{(q,3)} = \left( w_1^{(q,3)}, w_2^{(q,3)}, w_3^{(q,3)}, \dots, w_{N_2}^{(q,3)} \right)^T, \quad q = \overline{1, N_3}$$

где  $w_1^{(q,3)}, w_2^{(q,3)}, w_3^{(q,3)}, \dots, w_{N_2}^{(q,3)}$ , – весовые коэффициенты  $q$ -го нейрона для выходов первого, второго, третьего и  $N_2$ -го нейрона второго скрытого слоя первого модуля,  $(q, 3)$  – нейрон  $q$  третьего слоя,  $N_3$  – количество нейронов в выходном слое первого модуля ( $N_3 = 4$ ).

Соответственно, если обозначим случайную величину  $r^{(q,3)}$  для третьего слоя первого модуля, то выражения для взвешенной суммы линейной комбинаций входных воздействий нейрона  $q$  третьего скрытого слоя первого модуля примет вид:

$$u^{(q,3)} = \sum_{p=1}^{N_2} (o^{(p,2)} \cdot r^{(q,3)} \cdot w_{N_2}^{(q,3)} + b_{N_3}^{(q,3)}), \quad (2.28)$$

где  $b_{N_3}^{(q,3)}$  – порог для  $q$  - го нейрона третьего слоя первого модуля.

Следовательно, выход  $q$  - го нейрона выходного слоя первого модуля примет вид:

$$o^{(q,3)} = \hat{Y}_q = \varphi^{III}(u^{(q,3)}),$$

где  $\varphi^{III}(u^{(q,3)})$  – функция активации  $q$  - го нейрона третьего слоя первого модуля.

В нашем случае, экспериментальным способом выбраны коэффициенты прореживания  $P = 0,3$  для второго и третьего слоев каждого модуля, а также для второго слоя интегратора.

Таким образом, структурная регуляризация позволит минимизировать вероятность переобучения модульной нейронной сети при допустимо максимальном количестве эпох обучения. Важно отметить, что прореживание применяется только во время обучения, следовательно, на этапе тестирования прореживание не производится [92-100, 105-107].

После того как была обоснована четырехмодульная нейронная сеть и ее параметры (которые представлены в таблице 2.5), были проведены серии вычислительных экспериментов на разнообразных (непересекающихся) пропорциях выборок данных для оценки качества работы сети [79, 80].

**Таблица 2.5.** Основные параметры модульной нейронной сети [79, 80]

Параметры сети	Модуль 1	Модуль 2	Модуль 3	Модуль 4	Интегратор
Количество входов	8	22	5	35	-
Количество нейронов первого слоя	97	97	97	97	16
Функция активации первого слоя	-	-	-	-	ReLU
Коэффициент прореживание (dropout)	0,3	0,3	0,3	0,3	0,3
Количество нейронов второго (скрытого) слоя	52	52	52	52	128
Функция активации второго слоя	ReLU	ReLU	ReLU	ReLU	Sigmoid
Коэффициент прореживание (dropout)	0,3	0,3	0,3	0,3	-
Количество нейронов выходного слоя	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 [79, 80], что точность работы четырехмодульной нейронной сети, которая имеет вероятность правильного прогнозирования с распознаванием видов прихвата 0,96, превосходит точность работы полносвязанной сети [78], имеющий вероятность правильного прогнозирования с распознаванием видов прихвата 0,935.

## **2.6 Алгоритм обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины в процессе проектирования и бурения скважины**

После того как были завершены все этапы обучения, оптимизации и оценки качество работы модели, осуществляют процедуру прогнозирования прихвата технологического инструмента по глубине ствола скважины по двум возможным вариантам выполнения.

*Вариант 1.* Прогнозирование в процессе бурения скважины.

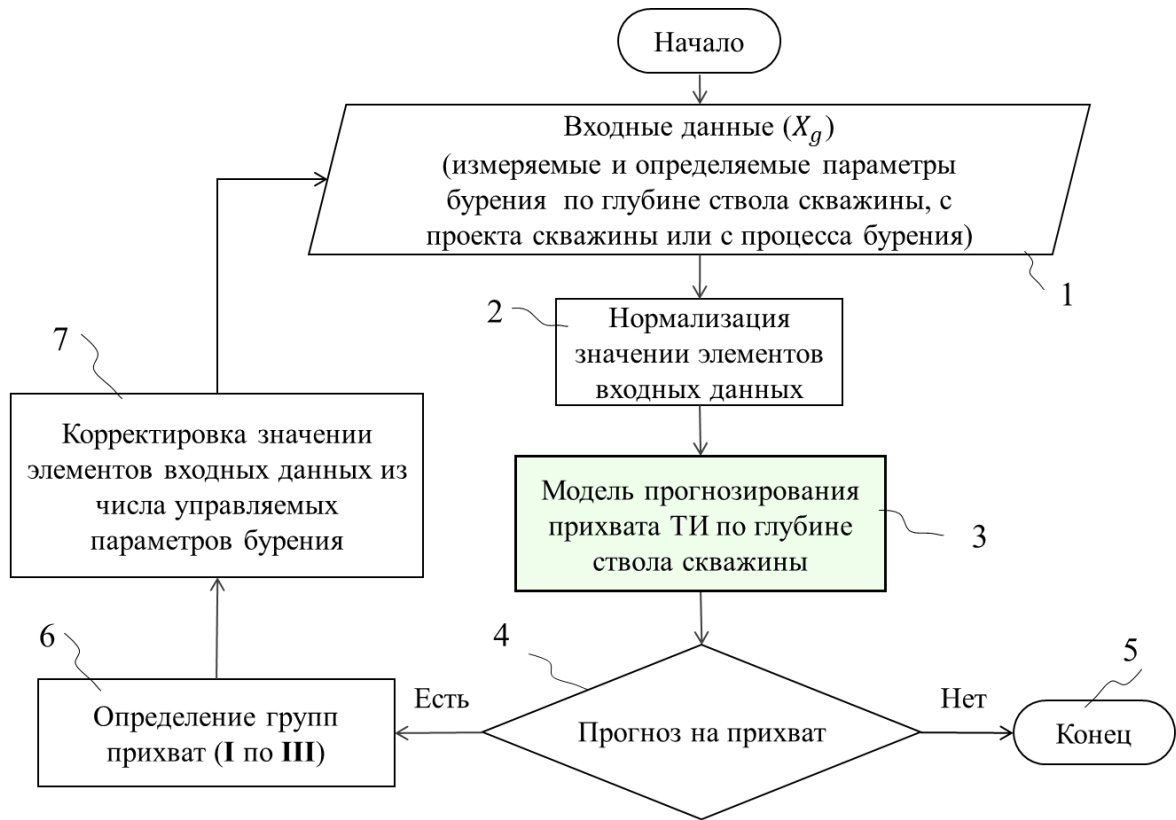
Измеряют и определяют значения элементов входных данных  $X_{1.1}, X_{1.2}, X_2, X_3, \dots, X_g$ , из числа параметров бурения (позиция 1, Рис. 2.16) для прогнозируемого интервала бурения бурящийся скважины. Далее, производят нормализацию значений элементов входных данных (позиция 2, Рис. 2.16) и передают в модель прогнозирования, которая представляет собой четырехмодульную нейронную сеть (позиция 3, Рис. 2.16), соответственно, модель в свою очередь выдает прогноз на прихват (позиция 4, Рис. 2.16). Если модель прогнозирует отсутствие прихвата, то на этом завершается процедура прогнозирования для имеющихся значений элементов входных данных (позиция 5, Рис. 2.16). Если модель прогнозирует прихват, с указанием группы прихвата (позиция 6, Рис. 2.16), то необходимо скорректировать значения элементов входных данных из числа управляемых параметров бурения (позиция 7, Рис. 2.16) и повторять процедуру прогнозирования до тех пор, пока не достигается отрицательного прогноза на прихват. Тем не менее, так же необходимо обращать внимание на значение элементов входных данных из числа неуправляемых

параметров бурения и провести проверку правильности расчетов и определение этих параметров.

*Вариант 2. Прогнозирование на стадии проектирование скважины.*

Рассчитывают, выбирают и определяют значения элементов входных данных  $X_{1.1}$ ,  $X_{1.2}$ ,  $X_2$ ,  $X_3$ , ...,  $X_g$ , из числа параметров бурения (позиция 1, Рис. 2.16) для прогнозируемого интервала проекта скважины. Далее, производят нормализацию значений элементов входных данных (позиция 2, Рис. 2.16) и передают в модель прогнозирования, которая представляет собой четырехмодульную нейронную сеть (позиция 3, Рис. 2.16), соответственно, модель в свою очередь выдает прогноз на прихват (позиция 4, Рис. 2.16). Если модель прогнозирует отсутствие прихвата, то на этом завершается процедура прогнозирования для имеющихся значений элементов входных данных (позиция 5, Рис. 2.16). Если модель прогнозирует прихват, с указанием группы прихвата (позиция 6, Рис. 2.16), то необходимо скорректировать значения элементов входных данных из числа управляемых параметров бурения (позиция 7, Рис. 2.16) и повторять процедуру прогнозирования до тех пор, пока не достигается отрицательного прогноза на прихват. Тем не менее, так же необходимо обращать внимание на значение элементов входных данных из числа неуправляемых параметров и провести проверку правильности расчетов и определение этих параметров.





**Рис. 2.16.** Алгоритм обработки данных для прогнозирования прихвата технологического инструмента по глубине ствола скважины.

Выше рассмотренный алгоритм обработки данных и модель прогнозирования была реализована с использованием промысловых архивных данных о прихватах ВНИИКРнефти, ОАО «НАФТУ ГАЗ» (Республика Таджикистан), а также промысловых данных ООО «НК ПАРИТЕТ», ООО «РУСГЕОСЕРВИС» по 166 образцам данных, в том числе 38 из них – дифференциальный прихват, 49 – прихват вследствие геометрических изменений ствола скважины, 59 – прихват вследствие зашламования или закупоривания кольцевого пространства твердыми частицами, и 20 – образцов, в которых отсутствуют прихваты. В результате, были получены прогнозные значения, показывающий вероятность возникновения прихватов (с указанием группы). Модель демонстрировал прогнозирования прихватов с вероятности 0,96, (правильно спрогнозировал 23 случая из 24).

## 2.7 ВЫВОДЫ ПО ГЛАВЕ 2

1. Предложена модифицированная классификация прихватов по механизмам, причинам, факторам и признакам их возникновения. А также по результатам анализа методов сбора информации о свойствах, параметрах и режимах процесса бурения скважины, предложена классификация набора данных о прихватах по глубине ствола скважины и по времени бурения скважины;

2. 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 долевыми значения этих элементов данных и повышающий информативность входных данных нейронной сети [78-80];

3. Предложена 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;

4. Разработана модель прогнозирования прихвата технологического инструмента по глубине ствола скважины, на основе трехслойной полносвязанной нейронной сети, с оптимальными параметрами. Кроме того, на основе четырехмодульной нейронной сети, разработана модель прогнозирования прихвата технологического инструмента по глубине ствола скважины, где структуры и параметры каждого модуля идентичны между собой, и представляют структуру и параметры трехслойной полносвязанной нейронной сети. Модель, состоящая из четырехмодульной нейронной сети, продемонстрировала вероятность правильного прогнозирования с распознаванием видов прихвата на экспериментальных образцах тестового мини набора 0,96;

5. Соответственно, на основе модели прогнозирования прихвата, состоящая из четырехмодульной нейронной сети, разработан алгоритм обработки данных

для прогнозирования прихвата технологического инструмента по глубине ствола скважины в процессе проектирования и бурения скважины;

6. В разработке модели прогнозирования прихвата технологического инструмента по глубине ствола скважины применялись важные и обобщающие факторы, такие как типы горных пород, компоненты понизителя вязкости, компоненты понизителя водоотдачи, компонент ингибирующей добавки, компонент смазывающей добавки, в качестве элементов входных данных. Это позволило модели прогнозировать прихваты по глубине ствола скважины, с высокой долей вероятности (0,96), что более чем на 20% превосходит по точности традиционных методов [16-21].

### ГЛАВА 3. РАЗРАБОТКА НЕЙРОСЕТЕВОЙ МОДЕЛИ ПРОГНОЗИРОВАНИЯ ПРИХВАТА ТЕХНОЛОГИЧЕСКОГО ИНСТРУМЕНТА ПО ВРЕМЕНИ БУРЕНИЯ СКВАЖИНЫ

#### 3.1 Анализ и формирование перечня элементов входных данных по времени бурения скважины

##### 3.1.1 Перечень элементов входных данных по времени бурения скважины

Реологические, технико-технологические свойства, параметры и режимы бурения, по времени бурения скважины – это набор многомерных временных рядов, записываемые станциями ГТИ и буровым персоналом в процессе строительства скважины.

Перечень элементов входных данных по времени бурения скважины состоит из таких свойств, параметров и режимов бурения как:  $X_{1.1}$  – детальный механический каротаж, мин/м;  $X_{1.2}$  – механическая скорость бурения, м/ч;  $X_{1.3}$  – скорость бурения, м/ч;  $X_{1.4}$  – суммарное содержание газов в растворе, %;  $X_{2.1}$  – температура бурового раствора на входе скважины, °С;  $X_{2.2}$  – температура бурового раствора на выходе из скважины, °С;  $X_{2.3}$  – плотность бурового раствора на входе скважины, г/см<sup>3</sup>;  $X_{2.4}$  – плотность бурового раствора на выходе из скважины, г/см<sup>3</sup>;  $X_{2.5}$  – условная вязкость, с;  $X_{2.6}$  – пластическая вязкость, Па·с;  $X_{2.7}$  – статическое напряжение сдвига бурового раствора (при одной минуте в покое  $CHC_1$ ), мгс/см<sup>2</sup>;  $X_{2.8}$  – статическое напряжение сдвига бурового раствора (при 10 минут в покое  $CHC_{10}$ ), мгс/см<sup>2</sup>;  $X_{2.9}$  – водоотдача за 30 мин., см<sup>3</sup>;  $X_{2.10}$  – толщина фильтрационной корки, мм;  $X_{2.11}$  – содержание смазывающего вещества (нефти) в буровом растворе, %;  $X_{2.12}$  – содержание песка (твердых частиц), %;  $X_{2.13}$  – водородный показатель «рН», 1÷14;  $X_{2.14}$  – удельный вес бурового раствора, Н/м<sup>3</sup>;  $X_{3.1}$  – наружный диаметр долота, мм;  $X_{3.2}$  – длина компоновки низа бурильной колонны, м;  $X_{3.3}$  – зазор между стенкой скважины и наружным диаметром максимально длинной части компоновки низа бурильной колонны (КНБК), мм;  $X_{3.4}$  – частота вращения долота (забойного двигателя, ротора), об/мин.;  $X_{3.5}$  – глубина нахождения забоя скважины, м;  $X_{3.6}$  – зенитный

угол участка ствола скважины, °;  $X_{3.7}$  – глубина нахождения инструмента (долота), м;  $X_{3.8}$  – положение талевого блока, м;  $X_{3.9}$  – вес технологического инструмента (вес на крюке), кН;  $X_{3.10}$  – осевая нагрузка на долото, кН;  $X_{3.11}$  – момент вращения на валу ротора или забойного двигателя, кН·м;  $X_{3.12}$  – количество свечей находящейся в стволе скважины, шт;  $X_{3.13}$  – давление на стояке бурового насоса, кПа, атм;  $X_{3.14}$  – ход поршня бурового насоса №1, м;  $X_{3.15}$  – ход поршня бурового насоса №2, м;  $X_{3.16}$  – расход бурового раствора на входе скважины ( $Q_1$ ), лит./с;  $X_{3.17}$  – расход бурового раствора на выходе из скважины ( $Q_2$ ), лит./с;  $X_{3.18}$  – суммарный объем бурового раствора в активных емкостях, м<sup>3</sup>;  $X_{3.19}$  – скорость спускоподъемных операций (СПО), м/мин.

По характеру описаний, перечисленные элементы данных, условно разделяются на:

- косвенно-геомеханические параметры горных пород ( $X_{1.1}$  -  $X_{1.4}$ );
- технологические и реологические параметры и свойства бурового раствора ( $X_{2.1}$  -  $X_{2.14}$ );
- технико-технологические параметры и режимы бурения ( $X_{3.1}$  -  $X_{3.19}$ ).

А также по характеру изменчивости по времени, в процессе бурения скважины, эти элементы данных разделяются на  $P_{stat}$  – статические ( $X_{3.1}$ ,  $X_{3.2}$ ,  $X_{3.3}$ ,  $X_{3.4}$ ) и  $P_{din}$  – динамические ( $X_{1.1}$  -  $X_{1.4}$ ,  $X_{2.1}$  -  $X_{2.14}$ ,  $X_{3.5}$  -  $X_{3.19}$ ) свойства, параметры и режимы.

### 3.1.2 Введение дополнительного элемента входных данных

Выше перечисленные элементы данных по времени бурения, из числа технико-технологических свойств, параметров и режимов бурения сами по себе полноценно не могут отображать или описать все условия вызывающие процесс возникновения прихватов. Для этого, необходимо рассчитать и вводить дополнительный элемент данных, отображающие факторы, причины и признаки возникновения прихватов.

В качестве такого элемента, рассмотрим – *длина технологического инструмента, находящегося в зоне открытого ствола*, которого для удобства обозначим как  $X_{3.20}$ . Этот параметр определяется выражением:

$$X_{3.20} = X_{3.7} - h_{bashOK}, \quad (3.1)$$


при условии, что

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

где  $h_{bashOK}$  – глубина нахождения башмака обсаженной колонны.

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 [1-3].



**Рис. 3.1.** Конструкция скважины с указанием параметра  $X_{3.20}$ .

Как известно [1-12], в 99% случаев, прихваты происходят в интервалах открытого ствола, то есть при значениях параметра  $X_{3.20}$  больше нуля (см. Рис. 3.1). Соответственно, чем больше значения этого параметра, тем выше риски возникновения прихвата. Следует отметить, что в тех интервалах ствола скважины, где значения параметра  $X_{3.20}$  равны нулю, нет необходимости производить процедуру прогнозирования прихвата, так как в этих интервалах

риски возникновения прихватов практически сводятся к нулю. Соответственно, нулевые значения этого параметра при анализе данных могут служить в качестве фильтра, по которым можно исключать ложные прогнозы прихвата.

Следовательно, в имеющийся перечень элементов данных, введем параметр  $X_{3.20}$  – длина технологического инструмента, находящегося в зоне открытого ствола, м.

### **3.1.3 Декомпозиция данных о процессе возникновения прихвата**

По результатам тщательного анализа имеющихся временных рядов из набора производственных данных о прихватах по времени бурения, было установлено, что процесс возникновения и ликвидация прихвата последовательно сопровождается четырьмя подпроцессами, такими как: предприхватный, прихватный, послеприхватный, и штатный подпроцессы. Причем, первые 3 из них часто протекают последовательно.

Соответственно, было принято решение, декомпозировать процесс возникновения и ликвидации прихвата на подпроцессы, и для удобства обозначить их целевыми переменными:  $Y_1$  – 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 технологического инструмента в стволе скважины на возможные риски возникновения прихвата.

### **3.1.4 Критерии распознавания подпроцессов прихвата**

В промышленном бурении не существует единого критерия оценки состояния технологического инструмента на риск возникновения прихвата, а существует ряд критериев, каждый из которых дает относительную оценку для конкретных условий. Это связано с многообразием механизмов и причин возникновения прихватов, которые могут возникнуть как по отдельности, так и в различных комбинациях.

Учитывая, что в рассматриваемой задаче прихват декомпозируется на четыре подпроцесса, в качестве критериев будем рассматривать причины и признаки возникновения прихватов, перечень которых был представлен в таблице 2.1. По этим критериям можно достоверно распознавать подпроцессы прихвата.

### 3.1.5 Сегментация многомерных временных рядов из набора данных по времени бурения скважины

**Определение.** Сегментом многомерного временного ряда

$$X = \begin{bmatrix} X_{1.1(0)}, \dots, X_{1.1(t)} \\ X_{1.2(0)}, \dots, X_{1.2(t)} \\ X_{1.3(0)}, \dots, X_{1.3(t)} \\ \dots \\ X_{3.20(0)}, \dots, X_{3.20(t)} \end{bmatrix}, \quad (3.2)$$

будем называть любую его непрерывную подпоследовательность:

$$S = \begin{bmatrix} X_{1.1(t_i)} \\ X_{1.2(t_i)} \\ X_{1.3(t_i)} \\ \dots \\ X_{3.20(t_i)} \end{bmatrix}, \quad (3.3)$$

где  $0 \leq t_i \leq t$ .

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, осуществлялся по четырем подпроцессам прихвата ( $Y_1$ ,  $Y_2$ ,  $Y_3$ ,  $Y_4$ ), с применением критериев распознавания этих подпроцессов, с учетом анализа таких материалов скважин как отчеты, сводки, акты, геолого-технические наряды, проектные документации, журналы оповещения оператора ГТИ и т.п.




На рисунке 3.2, из фрагмента записи журнала станции ГТИ, приведена иллюстрация сегментации временного ряда, на примере возникновения дифференциального прихвата:

- временные интервалы выделяются и сегментируются как  $Y_4$  – штатные подпроцессы, если изменения значений свойств, параметров и режимов бурения находятся в допустимом диапазоне, которые утверждены в проекте скважины. Например, на рисунке 3.2 временной интервал соответствующий штатному подпроцессу выделен и обозначен переменной  $Y_1$ ;

- временные интервалы выделяются и сегментируются как  $Y_1$  – предприхватные подпроцессы, если в этом интервале происходят изменения значений тех свойств, параметров и режимов бурения, которые в соответствие таблицы 2.1 являются признаками причин возникновения прихватов. Например, на рисунке 3.2 это характеризуется резким падением объема бурового раствора в приемной емкости (см. выделанную область 1), а также резким увеличением механической скорости бурения (см. выделанную область 2);

- временные интервалы выделяются и сегментируются как  $Y_2$  – прихватные подпроцессы, если в данном интервале происходят внезапные изменения значений некоторых свойств, параметров и режимов бурения за пределы допустимого. Например, на рисунке 3.2 это характеризуется чрезмерным увеличением веса на крюке (см. выделанную область 3) за незначительным изменением положения талевого блока;

- временные интервалы выделяются и сегментируются как  $Y_3$  – послеприхватные подпроцессы, если в данном интервале происходят постепенные восстановление изменения значений некоторых свойств, параметров и режимов бурения в сторону допустимого предела. Например, на рисунке 3.2 это характеризуется постепенным восстановлением веса на крюке и диапазона расхаживания инструмента на длину свеча (см. Рис. 3.2, выделенный и обозначенный интервал  $Y_3$ ).



**Рис. 3.2.** Иллюстрация сегментации временного ряда из набора данных по времени бурения, на примере дифференциального прихвата, на фрагменте журнала станции ГТИ:  $Y_1$  – предприхватный подпроцесс,  $Y_2$  – прихватный подпроцесс,  $Y_3$  – послеприхватный подпроцесс,  $Y_4$  – штатный подпроцесс, **1**, **2** и **3** – выделанная область проявления признаков возникновения подпроцессов.

Для решаемой задачи, представленный метод сегментации набора данных по времени бурения, позволить модели прогнозирования прихвата по ранним признакам своевременно обнаруживать и локализовать риски и причины возникновения прихватов.

### 3.1.6 Методика формирования перечня репрезентативных элементов входных данных по времени бурения

*Расчет коэффициента корреляций для первичного отбора репрезентативных элементов входных данных по времени бурения.* Также как для набора данных по глубине ствола скважины, произведем расчет коэффициента корреляции методом Спирмена для набора данных по времени бурения [83, 87]. На рисунках 3.3 а, б, в, г, представлены результаты расчетов, в виде корреляционной матрицы.




Рис. 3.3 а. Корреляционная матрица для набора данных по времени бурения скважины, часть 1.




Рис. 3.3 б. Корреляционная матрица для набора данных по времени бурения скважины, часть 2.




Рис. 3.3 в. Корреляционная матрица для набора данных по времени бурения скважины, часть 3.

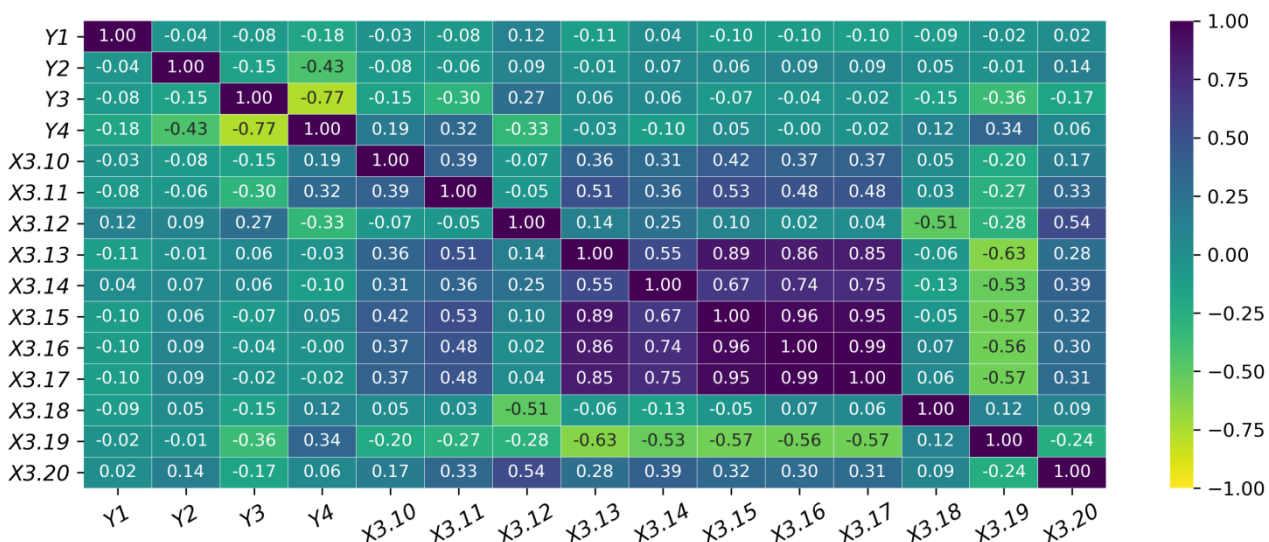


Рис. 3.3 г. Корреляционная матрица для набора данных по времени бурения скважины, часть 4.

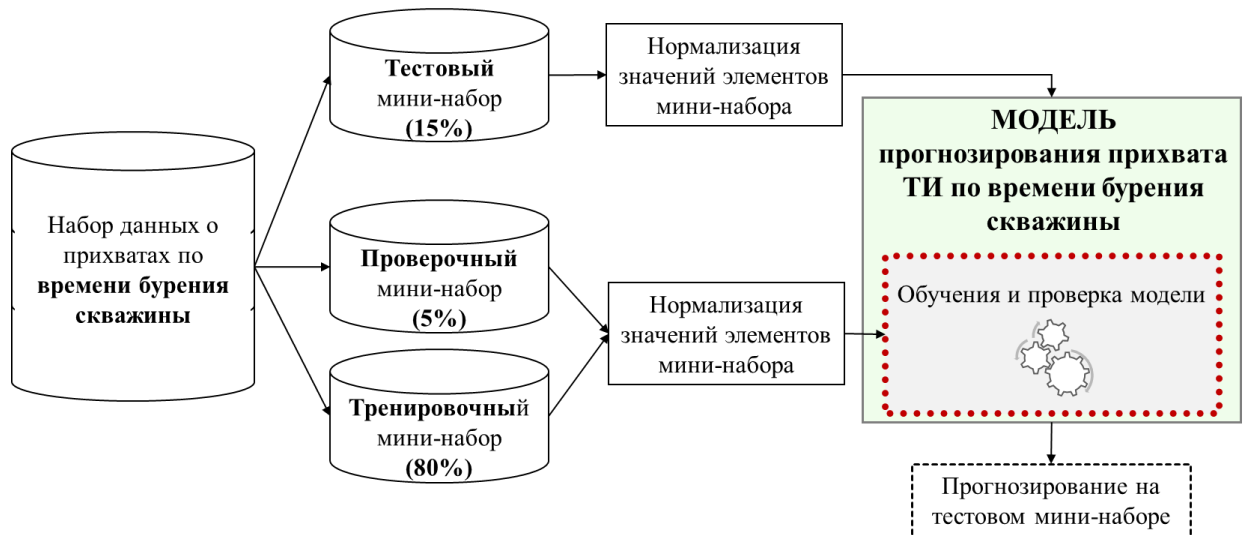
На основе полученных корреляционных матриц, по значениям коэффициентов корреляций, из 52 имеющихся элементов данных было отобрано 41 из них, как исходный объем репрезентативных элементов входных данных для проведения исследования, с целью оценки влияние отдельных элементов данных по времени бурения на качество работы сети.

*Отбор оптимального перечня репрезентативных элементов входных данных по времени бурения.* Отбор оптимального перечня элементов входных данных для набора данных по времени бурения, также осуществлялась на основе

вычислений на экспериментальных данных, с применением рассмотренной в главе 2 стратегией отбора элементов данных. Анализ результатов вычислений, показали, что из 41 имеющихся элементов входных данных, в том числе слабокоррелирующие, 38 из них имеют весомую значимость, и влияют на качество работы модели.

### 3.1.7 Разделение набора данных по времени бурения на тренировочный, проверочный и тестовый мини-наборы с последующей нормализацией значений элементов данных

Также как для набора данных по глубине ствола скважины, имеющейся набор данных о прихватах по времени бурения скважины разделим на три непересекающейся мини-наборы, причем 80% образцов на тренировочный, 5% образцов на проверочный и 15% на тестовый. Как было отмечено в 3 главе, нейронную сеть будем обучать на тренировочном мини-наборе, а процесс обучения сети будем оценивать на проверочном мини-наборе [88-90]. Соответственно, после того как завершится процесс обучения сети, сеть будем тестировать на тестовом мини-наборе (см. Рис. 3.4).



**Рис. 3.4.** Схема разделения и применения набора данных о прихватах по времени бурения скважины [89].

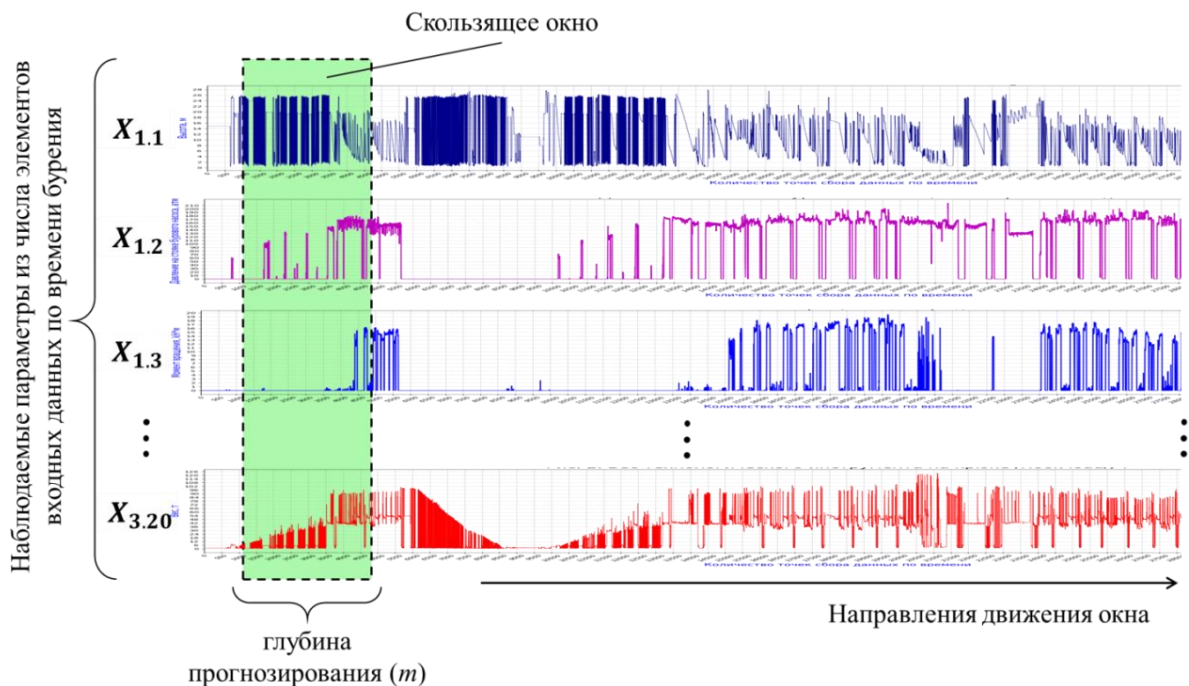
После того как набор данных о прихватах по времени бурения были разделены на мини-наборы, была произведена нормализация значений элементов

мини-наборов [88-90, 109-117]. Нормализация подробно была рассмотрена во второй главе данной работы.

### 3.2 Выбор и обоснование параметров скользящего окна

Для прогнозирования временных рядов используется метод скользящего окна. Метод скользящего окна – основан на алгоритме трансформации, позволяющем сформировать из членов временного ряда набор данных, который может служить обучающим множеством для построения модели прогнозирования.

Под окном в данном методе понимается временной интервал, содержащий набор значений входных элементов данных в виде временных наблюдений, которые используются для формирования выборки [108, 111, 112]. В процессе работы алгоритма, окно смещается по временной последовательности на единицу наблюдения, и каждое положение окна образует одну выборку [108, 111, 112]. Количество временных наблюдений ряда ( $m$ ), которые берутся в качестве входных значений, называется глубиной прогноза (см. Рис. 3.5) [88-90].



**Рис. 3.5.** Иллюстрация работы алгоритма скользящего окна с наборами входных данных по времени бурения, из числа многомерных временных рядов [88-90].



Как было отмечено в выше, перечень элементов входных данных по времени бурения скважины, в виде многомерных временных рядов, по характеру изменчивости по времени, в процессе бурения скважины, разделяются на:

$P_{stat}$  – статические ( $X_{3.1}, X_{3.2}, X_{3.3}, X_{3.4}$ ) свойства, параметры и режимы и  $P_{din}$  – динамические ( $X_{1.1} - X_{1.4}, X_{2.1} - X_{2.14}, X_{3.5} - X_{3.20}$ ) свойства, параметры и режимы.

Тогда обобщенно запишем перечень элементов входных данных по времени бурения скважины в следующем виде:

$$P = P_{din} + P_{stat}. \quad (3.4)$$

Далее, перечень динамических свойств, параметров и режимов бурения ( $P_{din}$ ) запишем в виде матрицы:

$$P_{din} = \begin{bmatrix} X_{1.1(t+0)} & X_{1.2(t+0)} & X_{1.3(t+0)} & X_{1.4(t+0)} & \dots & X_{3.20(t+0)} \\ X_{1.1(t+1)} & X_{1.2(t+1)} & X_{1.3(t+1)} & X_{1.4(t+1)} & \dots & X_{3.20(t+1)} \\ X_{1.1(t+2)} & X_{1.2(t+2)} & X_{1.3(t+2)} & X_{1.4(t+2)} & \dots & X_{3.20(t+2)} \\ X_{1.1(t+3)} & X_{1.2(t+3)} & X_{1.3(t+3)} & X_{1.4(t+3)} & \dots & X_{3.20(t+3)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ X_{1.1(t+m)} & X_{1.2(t+m)} & X_{1.3(t+m)} & X_{1.4(t+m)} & \dots & X_{3.20(t+m)} \end{bmatrix}, \quad (3.5)$$

где индексы  $(t + 0), (t + 1), (t + 2), (t + 3), \dots (t + m)$  показатель значений временных наблюдений ряда в момент времени 0, 1, 2, 3 до  $m$ . Следовательно,  $m$  – это количество временных наблюдений ряда.

Запишем матрицу (3.5) в виде транспонированного:

$$P_{din}^T = \begin{bmatrix} X_{1.1(t+0)} & X_{1.1(t+1)} & X_{1.1(t+2)} & X_{1.1(t+3)} & \dots & X_{1.1(t+m)} \\ X_{1.2(t+0)} & X_{1.2(t+1)} & X_{1.2(t+2)} & X_{1.2(t+3)} & \dots & X_{1.2(t+m)} \\ X_{1.3(t+0)} & X_{1.3(t+1)} & X_{1.3(t+2)} & X_{1.3(t+3)} & \dots & X_{1.3(t+m)} \\ X_{1.4(t+0)} & X_{1.4(t+1)} & X_{1.4(t+2)} & X_{1.4(t+3)} & \dots & X_{1.4(t+m)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ X_{3.20(t+0)} & X_{3.20(t+1)} & X_{3.20(t+2)} & X_{3.20(t+3)} & \dots & X_{3.20(t+m)} \end{bmatrix}^T, \quad (3.6)$$

Таким же образом, запишем в виде матрицы перечень элементов входных данных по времени бурения, из числа статических свойств, параметров и режимов бурения:

$$P_{stat} = \begin{bmatrix} X_{3.1(t+0)} & X_{3.2(t+0)} & X_{3.3(t+0)} & X_{3.4(t+0)} \\ X_{3.1(t+1)} & X_{3.2(t+1)} & X_{3.3(t+1)} & X_{3.4(t+1)} \\ X_{3.1(t+2)} & X_{3.2(t+2)} & X_{3.3(t+2)} & X_{3.4(t+2)} \\ X_{3.1(t+3)} & X_{3.2(t+3)} & X_{3.3(t+3)} & X_{3.4(t+3)} \\ \dots & \dots & \dots & \dots \\ X_{3.1(t+m)} & X_{3.2(t+m)} & X_{3.3(t+m)} & X_{3.4(t+m)} \end{bmatrix}, \quad (3.7)$$

так как  $P_{stat}$  – статические параметры и режимы не зависят от времени, следовательно, матрица  $P_{stat}$  примет вид столбцевой матрицы или вектора-строки:

$$P_{stat} = [X_{3.1} \quad X_{3.2} \quad X_{3.3} \quad X_{3.4}]. \quad (3.8)$$

### 3.2.1 Выбор и обоснование глубины прогнозирования

Как было отмечено выше, процесс возникновения и ликвидация прихвата декомпозируется на 4 подпроцессов:  $Y_1$  – предприхватный подпроцесс,  $Y_2$  – прихватный подпроцесс,  $Y_3$  – послеприхватный подпроцесс, и  $Y_4$  – штатный подпроцесс. Соответственно, процесс возникновения и ликвидация прихватов, это переход от одного подпроцесса к другому. Например, процесс возникновения прихвата это переход:

$$Y_4 \rightarrow Y_1 \rightarrow Y_2,$$

а процесс ликвидации прихвата это переход:

$$Y_2 \rightarrow Y_3 \rightarrow Y_4.$$

Так как данная работа посвящена прогнозированию прихватов, то нас интересует в первую очередь переход  $Y_4 \rightarrow Y_1 \rightarrow Y_2$ .

Следовательно, значения глубины прогнозирования ( $m$ ), которая представляет собой количество временных наблюдений ряда ( $m$ ), необходимо выбрать исходя из средней времени перехода  $Y_4 \rightarrow Y_1 \rightarrow Y_2$ , а также от шага агрегации (усреднении) значений элементов входных данных по времени [108-112]. Как показали результаты анализа имеющихся данных по времени бурения, средняя время перехода  $Y_4 \rightarrow Y_1 \rightarrow Y_2$  составляет до 30 минут. Это свидетельствует о том, что процессы возникновения прихватов можно



спрогнозировать или идентифицировать, если анализировать изменений всех значений свойств, параметров и режимов бурения за 30 минут.

Соответственно, для решаемой задачи, глубина прогнозирования ( $m$ ), была выбрана 30 единиц наблюдения. Единица наблюдения определяется агрегированием набора данных в течение одной минуты [108-117].

### **3.3 Выбор и обоснование типа и структуры нейронной сети**

#### **3.3.1 Выбор типа нейронной сети**

Как было отмечено в предыдущей главе, существует множество разновидностей и типов нейронных сетей. Для обработки табличных данных имеющих временной характер (значении которых упорядочены по времени), чаще всего применяются многослойные, рекуррентные и одномерные (1D) сверточные нейронные сети [109-117]. Рекуррентные и одномерные сверточные сети медленно обучаются, особенно когда массив обрабатываемого набора данных имеют большое количество входных векторов и тензоров, что сильно снижает производительность процесса обучения [91-101, 112-117]. В свою очередь, многослойные сети имеют преимущество перед рекуррентными и сверточными (1D) сетями, в плане простоты, производительности и в широком диапазоне настраиваемых параметров, для набора данных имеющих большое количество входных векторов и тензоров [93-101]. Так как в решаемой задачи, применяются данные состоящие из многомерных или мультивариационных временных рядов, целесообразно применять многослойные полносвязанные нейронные сети прямого распространения, методом обучения с учителем [93-97, 109, 113, 116, 117], что нами было сделано.

#### **3.3.2 Обоснование исходной структуры нейронной сети**

Для привязки скользящего окна к нейронной сети, необходимо преобразовать матрицы (3.4 и 3.6) элементов входных данных в одномерный вектор. Так как глубина прогнозирования составляет  $m = 30$  единиц наблюдения, тогда для динамических свойств, параметров и режимов будем иметь вектор  $\overline{P_{din}}$

с 1020-ю параметрами ( $34 \cdot 30 = 1020$ ), а также вектор статических свойств, параметров и режимов  $\overline{P_{stat}}$  с 4-мя параметрами.

Тогда, с учетом всех элементов входных данных по времени бурения ( $P$ ), будем иметь:  $\overline{P} = \overline{P_{din}} + \overline{P_{stat}} = 1020 + 4 = 1024$  входных параметров.

На основе выше сказанного и приведенных расчетов, в качестве исходной модели необходимо выбрать исходную структуру нейронной сети со следующими гиперпараметрами:


- входной слой с 1024 нейронами с линейной или ректификационной «ReLU» функцией активации;
- выходной слой из 4-х нейронов, так как имеющийся набор данных о прихватах по времени бурения сегментированы по четырем подпроцессам. В результате имеется 4 группы образцов данных ( $Y_1, Y_2, Y_3$ , и  $Y_4$ ).

Соответственно, так как решаемая задача относится к мульти-классовой классификации, то в выходном слое целесообразно применять функцию активации мягкого максимума «Softmax» [92-101, 109-114]. А также, в качестве функции ошибки, использовать категориальную перекрестную энтропию (*categorical cross-entropy*) [92-97, 109-112], которая подробно была рассмотрена во второй главе данной работы. Тогда для решаемой задачи уравнения категориальной перекрестной энтропий (см. уравнение 2.7), примет вид:

$$L_t = - \sum_{z=1}^4 Y_z \log(\hat{Y}_z), \quad (3.9)$$

где  $\hat{Y}_z$  – предсказанное моделью значение целевой переменной,  $Y_z$  – фактическое значение целевой переменной,  $L_t$  – мера ошибки [93, 109],  $z = \overline{1, 4}$ .

На основе вышесказанного, на рисунке 3.6 представлена структурная схема исходной двухслойной полносвязанной нейронной сети.



**Рис. 3.6.** Структурная схема исходной двухслойной полносвязанной нейронной сети.

Что касается типа оптимизатора и меры оценки качества работы сети, то также выберем в качестве оптимизатора «Adam» и меру «Accuracy» (ACC) для исходной сети. Мера ACC также подробно была рассмотрена во второй главе. Следует также отметить, что под долей точности в данной главе подразумевается вероятность правильного распознавания подпроцесса прихвата ( $Y_1, Y_2, Y_3, \text{ и } Y_4$ ).

### 3.3.3 Экспериментальный подбор параметров обучения и характеристики сети

Что касается определений количества промежуточных или скрытых слоев и количества нейронов в этих слоях, необходимо провести серию численных экспериментов с сопоставлением результатов точности работы сети.

Постановка задачи параметрической оптимизации, то есть поиска оптимального количества слоев и нейронов в слоях будет следующее [93-101]:

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

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

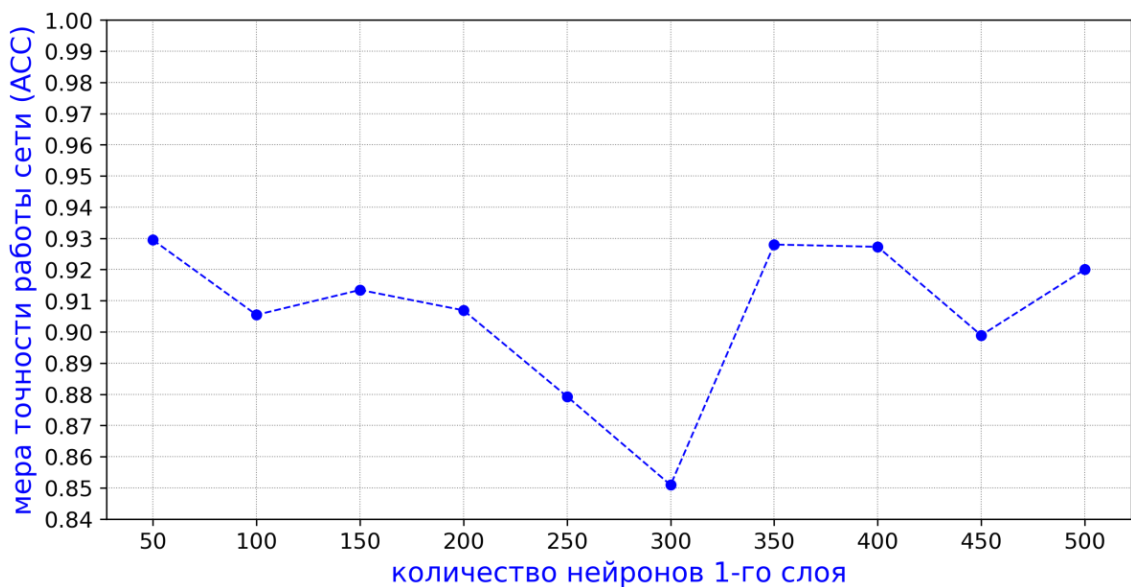
при которой средняя доля точности работы сети по всем образцам тестового мини-набора достигает своего максимума

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


Итак, 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 по ранее рассмотренной в главе 2 методике. Шаг последовательного перебора количество нейронов составляет 50.


Таким образом, были произведены серии вычислительных экспериментов для 8 слоев, не учитывая выходной слой, результаты которых (см. Рис. 3.7, 3.8, 3.9, 3.10, 3.11 и 3.12, а также таблица 3.1) показали, что для решаемой задачи оптимальное количество входного и промежуточных слоев составляет 5 (см. Рис. 3.12).



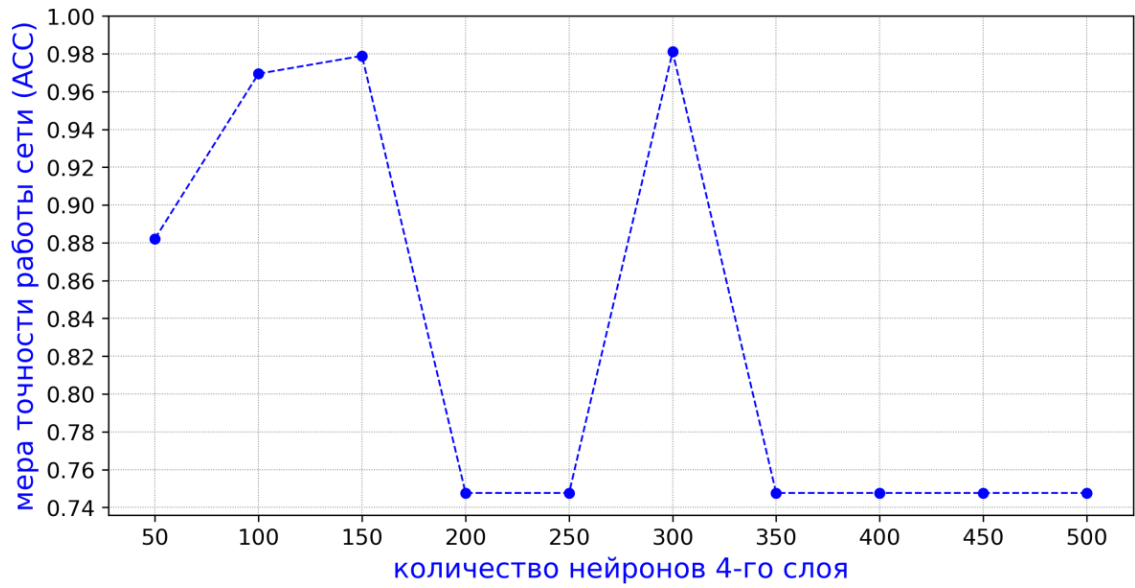
**Рис. 3.7.** График средней доли точности работы сети на тестовом мини-наборе в зависимости от количества нейронов в первом слое.




**Рис. 3.8.** График средней доли точности работы сети на тестовом мини-наборе в зависимости от количества нейронов во втором слое.



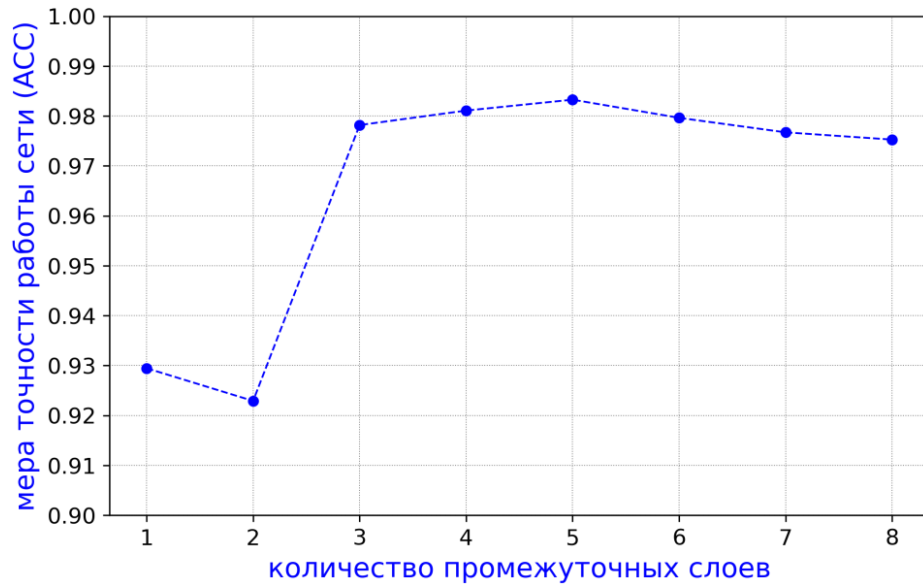
**Рис. 3.9.** График средней доли точности работы сети на тестовом мини-наборе в зависимости от количества нейронов в третьем слое.



**Рис. 3.10.** График средней доли точности работы сети на тестовом мини-наборе в зависимости от количества нейронов в четвертом слое.



**Рис. 3.11.** График средней доли точности работы сети на тестовом мини-наборе в зависимости от количества нейронов в пятом слое.



**Рис. 3.12.** График средней доли точности работы сети на тестовом мини-наборе в зависимости от количества промежуточных слоев.


Как видно из графика средней доли точности работы сети (см. Рис. 3.12), дальнейшее увеличение количество нейронных слоев не привели к повышению доли точности работы сети, а наоборот негативно повлияли.

**Таблица 3.1.** Сопоставления долей точности и ошибки работы сети в зависимости от количества нейронов в слоях

Количество нейронов	1-й слой		2-й слой		3-й слой		4-й слой		5-й слой		6-й слой		7-й слой		8-й слой	
	ACC_1	Loss_1	ACC_2	Loss_2	ACC_3	Loss_3	ACC_4	Loss_4	ACC_5	Loss_5	ACC_6	Loss_6	ACC_7	Loss_7	ACC_8	Loss_8
50	<b>0,92946</b>	<b>0,30725</b>	0,74764	0,74852	0,97746	0,09546	0,88218	0,21388	0,91273	0,21164	0,74764	0,74842	0,74764	0,74848	0,97327	0,08978
100	0,90546	1,00000	0,90036	0,23850	0,92727	0,17675	0,96946	0,10891	0,97164	0,07782	0,74764	0,74849	0,93673	0,12409	0,74764	0,74820
150	0,91346	0,45663	0,89818	0,28476	0,74764	0,74913	0,97891	0,05916	0,74764	0,67455	0,97018	0,08553	0,97673	0,07189	0,97527	0,08797
200	0,90691	0,64637	0,74764	0,74842	0,74764	0,74897	0,74764	0,74863	0,97018	0,08606	0,84436	0,42788	0,74764	0,74959	0,11346	1,96016
250	0,87927	1,00000	0,74764	0,74857	0,74764	0,74831	0,74764	0,74806	0,97600	0,06147	0,96509	0,09754	0,73091	0,56280	0,91491	0,18148
300	0,85091	0,57512	<b>0,92291</b>	<b>0,23614</b>	<b>0,97818</b>	<b>0,07659</b>	<b>0,98109</b>	<b>0,08203</b>	<b>0,98327</b>	<b>0,05548</b>	0,95709	0,11148	0,91855	0,27353	0,74764	0,75167
350	0,92800	1,00000	0,74764	0,63065	0,95273	0,14382	0,74764	0,74826	0,94036	0,14251	0,97964	0,07175	0,97091	0,09045	0,93964	0,16975
400	0,92727	0,84379	0,74764	0,71417	0,90982	0,30569	0,74764	0,74975	0,67418	1,00000	0,93891	0,15577	0,74764	0,74884	0,74764	0,74984
450	0,89891	1,00000	0,74764	0,74846	0,74764	0,74840	0,74764	0,74877	0,97236	0,06842	0,96436	0,12111	0,96873	0,08615	0,87636	0,29437
500	0,92000	1,00000	0,74764	0,61730	0,74764	0,74850	0,74764	0,74799	0,74764	0,74890	0,92364	0,17928	0,74764	0,74470	0,74764	0,74818

В таблице 3.1 ACC\_1, ACC\_2, ..., ACC\_8 – средняя доля точности работы сети по всем образцам тестового мини-набора для 1-го, 2-го, ..., 8-го слоя; Loss\_1, Loss\_2, ..., Loss\_8 – средняя доля ошибки работы сети по всем образцам тестового мини-набора для 1-го, 2-го, ..., 8-го слоя.


Исходя из вышесказанного, обоснованно выбрана следующая структура ПНС сети для решаемой задачи: шестислойная сеть, где первый слой состоит из 50 нейронов, начиная со 2-го по 5-го слоя по 300 нейронов в каждом слое, с ректификационными функциями активации «ReLU», и последний 6-й (выходной) слой состоит из 4-х нейронов с функцией активации мягкого максимума «SoftMax».




**Рис. 3.13.** Структурная схема итоговой полносвязанной шестислойной нейронной сети, для задачи прогнозирования прихвата ГИ по времени бурения скважины.

После того как были определены оптимальное количество слоев в сети и нейронов в слоях, также были проведены серии экспериментальных вычисления для нахождения наилучшего типа оптимизатора сети, при которой средняя доля точности работы сети достигает максимума, а средняя доля ошибки работы сети минимума. Результаты показали, что среди применяемых оптимизаторов, наилучшие результаты работы сети достигаются с применением оптимизатора «Adagrad» (см. Рис. 3.14, и 3.15). Более подробные характеристики и параметры итоговой полносвязанной шестислойной нейронной сети приведены в таблице 3.2.





**Рис. 3.14.** Средняя доля точности работы сети на тестовом мини-наборе при различных оптимизаторах.



**Рис. 3.15.** Средняя доля ошибки работы сети на тестовом мини-наборе при различных оптимизаторах.

**Таблица 3.2.** Конфигурация итоговой полносвязанной шестислойной нейронной сети

Параметры шестислойной полносвязанной нейронной сети		
Слои	Количество входов	1024
1	Количество нейронов / Активационная функция / Dropout	50/ - / -
2	Количество нейронов / Активационная функция / Dropout	300/ ReLU/0,3
3	Количество нейронов / Активационная функция / Dropout	300/ ReLU/0,3
4	Количество нейронов / Активационная функция / Dropout	300/ ReLU/ -
5	Количество нейронов / Активационная функция / Dropout	300/ ReLU/0,2
6	Количество нейронов выходного слоя	4
	Активационная функция выходного слоя	SoftMax
Функция ошибки сети:		Categorical cross-entropy
Тип оптимизатора сети:		Adagrad
Мера оценки качество работы сети:		Accuracy (ACC)
Размер мини-пакетов:		256
Оптимальное количество эпох обучения сети:		900-1000

Далее, была произведена тестирование модели прогнозирования прихвата ТИ по времени бурения на экспериментальных образцах тестового мини-набора. Результаты тестирования показали, что средняя доля точности работы модели составляет 0,98. Такая точность работы модели была достигнута благодаря системному подходу выбора оптимальных конфигурации параметров сети для решаемой задачи.

***Оценка значимости элемента данных  $X_{3,20}$  на качество работы сети.***

Как выше было отмечено, введенный новый элемент данных  $X_{3,20}$  – длина технологического инструмента, находящегося в зоне открытого ствола, является важным условием возникновения прихвата. Для того, чтобы оценить на сколько параметр  $X_{3,20}$  влияет на качество работы сети, была проведена повторное обучение и тестирование сети без учета и с учетом элемента  $X_{3,20}$  в перечне элементов входных данных сети. В качестве меры оценки качество работы сети помимо «точности» (ACC) применили такие меры как «аккуратность» (Precision), «полноту» (Recall), которые описываются следующими выражениями [92-96]:

$$Precision = \frac{TP}{TP + FP}, \quad (3.10)$$

$$Recall = \frac{TP}{TP + FN}. \quad (3.11)$$

где  $TP$  – (true positive) количество верно распознанного подпроцесса,  $TN$  – (true negative) количество верно распознанного отсутствие подпроцесса,  $FP$  – (false positive) количество неверно распознанного подпроцесса,  $FN$  – (false negative) количество неверно распознанного отсутствие подпроцесса.

Результаты тестирования сети без учета и с учетом элемента данных  $X_{3.20}$  представлены в таблицах 3.3 и 3.4.

**Таблица 3.3.** Значений качество работы сети на тестовом мини-наборе

Мера оценки	без учета $X_{3.20}$				с учетом $X_{3.20}$				улучшения 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 3.4.** Матрица неточности работы сети (confusion matrices)

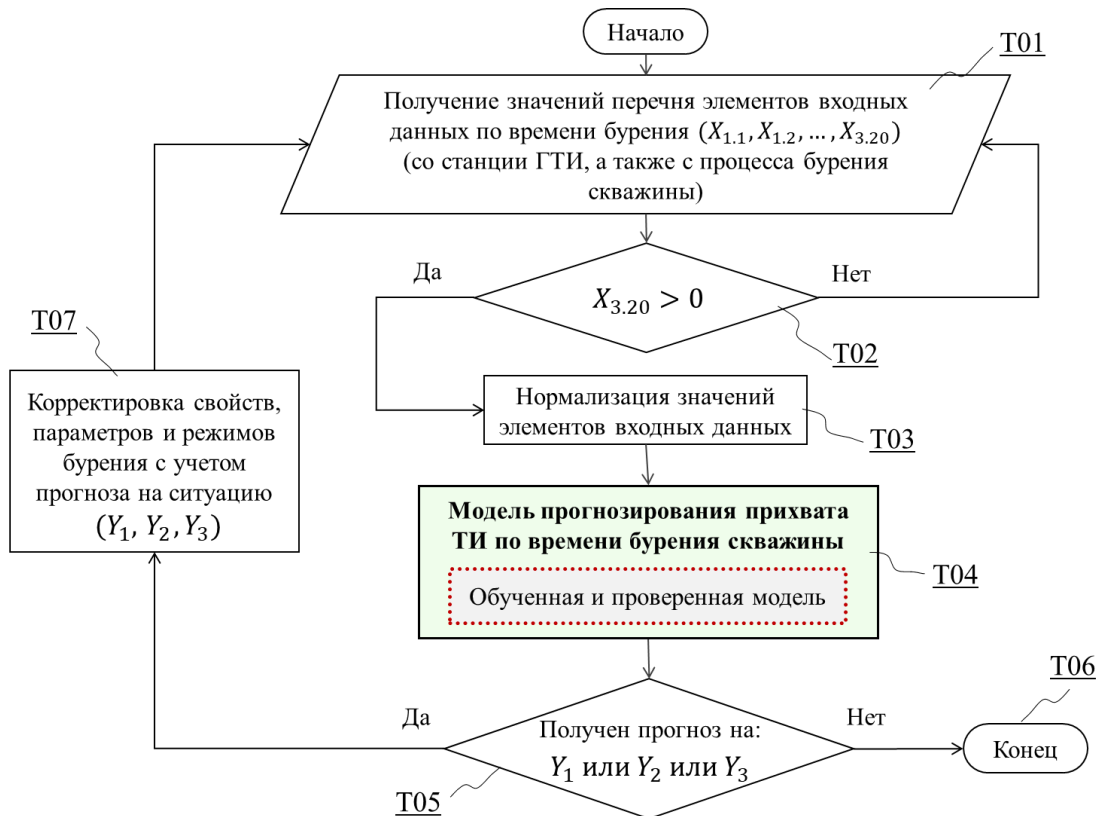
		без учета $X_{3.20}$				с учетом $X_{3.20}$			
		сетью распознанные подпроцессы				сетью распознанные подпроцессы			
		$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_1$	$Y_2$	$Y_3$	$Y_4$
действительные подпроцессы	$Y_1$	67	2	1	6	69	0	0	7
	$Y_2$	0	451	16	19	1	459	16	10
	$Y_3$	0	4	320	3	0	1	326	0
	$Y_4$	3	14	9	1507	1	4	8	1520

### 3.4 Алгоритм обработки данных для прогнозирования прихвата технологического инструмента по времени бурения скважины

После того как были завершены все этапы обучения, оптимизации и тестирование модели, была произведена процедура прогнозирования прихвата технологического инструмента на неразмеченных данных из процесса бурения скважины (в режиме реального времени).

Алгоритм обработки данных для прогнозирования прихвата технологического инструмента по времени бурения скважины осуществляется следующим образом [90]: измеряют, рассчитывают, выбирают и определяют свойства, параметры и режимы бурения по выше рассматриваемому списку перечня элементов входных данных по времени бурения, со станции геолого-технологического исследования (ГТИ), а также с процесса бурения для прогнозируемой (бурящейся) скважины (позиция T01 на Рис. 3.16); далее сравнивают (позиция T02 на Рис. 3.16) значение параметра  $X_{3,20}$  – длины технологического инструмента, находящийся в зоне открытого ствола: если  $X_{3,20} \leq 0$ , то цикл замыкается с позицией T01 (Рис. 3.16) до тех пор, пока значения  $X_{3,20}$  не станет больше нуля; если значения  $X_{3,20} > 0$ , то производят нормализацию значений полученных свойств, параметров и режимов (элементов входных данных по времени бурения) (позиция T03 на Рис. 3.16) и передают в модель прогнозирования прихвата ГТИ по времени бурения (позиция T04 на Рис. 3.16), которая в свою очередь выдает прогноз (позиция T05 на Рис. 3.16):  $Y_1$  – предприхватный подпроцесс,  $Y_2$  – прихватный подпроцесс,  $Y_3$  – послеприхватный подпроцесс, и  $Y_4$  – штатный подпроцесс. Если модель прогнозирует отсутствие прихвата ( $Y_4$  – штатный подпроцесс) (позиция T06 на Рис. 3.16), то на этом завершается процедура прогнозирования для имеющихся значений элементов входных данных для момента времени  $t+m$ . Если модель выдает такие прогнозы как  $Y_1$  – предприхватный подпроцесс,  $Y_2$  – прихватный подпроцесс,  $Y_3$  – послеприхватный подпроцесс, тогда необходимо скорректировать (предпринимать меры по предотвращении прихватоопасной ситуации) значения

свойств, параметров и режимов бурения (позиция T07 на Рис. 3.16) для имеющихся входных данных в момент времени  $t+m$ , и повторять процедуру прогнозирования для значений входных данных (позиция T01 на Рис. 3.16) со смешанным окном прогнозирования на следующий временной шаг  $t+m$ , до тех пор, пока модель не выдаст прогноз  $Y_4$  (позиция T06 на Рис. 3.16), которая означает отсутствие прихвата.



**Рис. 3.16.** Алгоритм обработки данных для прогнозирования прихвата ТИ по времени бурения скважины [90].

Рассмотренный алгоритмы обработки данных и модель прогнозирования прихвата технологического инструмента по времени бурения скважины, была реализована с использованием промысловых данных о прихватах Российских нефтегазовых и сервисных компаний, таких как ОАО «ПАРИТЕТ» и ОАО «РУСГЕОСЕРВИС», записанными станциями ГТИ «ГЕОТЕСТ-5» за период с 2016 по 2021 гг. В результате, моделью были получены прогнозные значения, показывающие вероятность возникновения прихватоопасных ситуации. Модель продемонстрировала достоверность прогнозирования прихвата ТИ на экспериментальных тестовых данных с вероятностью 0,98.

### 3.5 ВЫВОДЫ ПО ГЛАВЕ 3

1. Для полноты описания всех условий, вызывающих процесс возникновения прихвата, а также с целью исключений ложных прогнозов на прихват, введен новый элемент данных,  $X_{3.20}$  – длина технологического инструмента, находящегося в зоне открытого ствола, для набора данных по времени бурения;

2. 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 состояние технологического инструмента в стволе скважины на возможные риски возникновения прихвата. А также предложен ряд критериев распознавания подпроцессов прихвата, из числа причин и признаков возникновения прихватов.

3. Предложен метод сегментации многомерных временных рядов из набора данных по времени бурения по четырем подпроцессам прихвата ( $Y_1, Y_2, Y_3, Y_4$ ), с применением критериев распознавания этих подпроцессов. Предложенный метод позволит по ранним признакам своевременно обнаруживать и локализовать риски и причины возникновения прихватов;

4. Предложена методика формирования перечня репрезентативных элементов входных данных по времени бурения. Методика состоит из расчета коэффициентов корреляции и отбора оптимального перечня репрезентативных элементов входных данных по времени бурения скважины.

5. Разработана модель прогнозирования прихвата технологического инструмента по времени бурения скважины, которая состоит из шестислойной полносвязанной нейронной сети с оптимальными параметрами. В разработке модели применялись разнородные и обобщающие перечни свойств, параметров и режимов бурения, что позволили полученной модели быть более чувствительной

и универсальной к данным из скважин других месторождений. Применяемый способ сегментации обучающего набора данных, позволил полученной модели прогнозировать прихваты по ранним признакам на ранних и промежуточных стадиях их возникновения, что позволит буровому персоналу своевременно предпринимать меры по их предотвращению. Следует также отметить, что обучающая выборка по времени, из многомерных временных рядов, была сформулирована с помощью скользящего окна, которая позволила полученной модели учитывать динамические и статические свойства, параметров и режимов бурения. Это позволило полученной модели прогнозировать прихват технологического инструмента на экспериментальных тестовых данных с вероятностью 0,98, что более чем на 18% превосходит по точности существующих методов [36-57];

6. Разработан алгоритм обработки данных для прогнозирования прихвата технологического инструмента по времени бурения скважины на основе полученной модели, который позволил уменьшить время процедуры прогнозирования, а также исключить ложный прогноз в обсаженных интервалах ствола скважины во время спускоподъемных и других технологических операций.

## **ГЛАВА 4. ИССЛЕДОВАНИЕ ЭФФЕКТИВНОСТИ ПРЕДЛОЖЕННЫХ МОДЕЛЕЙ ПРОГНОЗИРОВАНИЯ ПРИХВАТА ТЕХНОЛОГИЧЕСКОГО ИНСТРУМЕНТА**

На основе моделей и алгоритмов прогнозирования прихвата ТИ по глубине ствола скважины и по времени бурения, которые были рассмотрены в главах 3 и 4, произведем прогнозирование на примере имеющийся данных о процессе бурения скважины № 72, куст №7 БИС, Мегионского нефтяного месторождения, Нижневартовского района Ханты-Мансийского автономного округа Тюменской области. Бурения ввелась с 14.03.2019 г. по 24.04.2019 г., буровой установкой БУ-3000 ЭУК-1М, и была завершена 18-ю технологическими рейсами. Прихват ТИ произошел на глубине 2660 м, в процессе подъема инструмента с глубины 3126 м. до 2660 м. в 6-том рейсе, когда ввелась бурения с 220,7 мм долотом под эксплуатационную колонну. В документациях скважины, в том числе акта аварий, суточных сводок и рапортов подчеркивается, что прихват произошел по причине неустойчивости ствола скважины.

### **4.1 Прогнозирование прихвата технологического инструмента по глубине ствола скважины**

Как было отмечено во второй главе данной работы, процедура прогнозирования прихвата ТИ по глубине ствола скважины осуществляется последовательно, и по интервалам бурения. Соответственно, для выше упомянутой скважины были произведены процедуры прогнозирования прихвата ТИ по глубины ствола скважины, на проектных и фактических данных о свойствах, параметрах и режимах бурения. Результаты прогнозирования представлены в таблице 4.1, в виде значения вероятностей возникновения группы прихват, а также отсутствия прихвата, для тех интервалах бурения, в которых имелись высокие пластовые давления.



**Табл. 4.1.** Результаты прогнозирования прихвата ТИ по глубине ствола скважины

Интервал бурения, м.	Вероятность возникновения или отсутствия прихвата			
	$Y_1$	$Y_2$	$Y_3$	$Y_4$
1853-1863	0,0002	0,0344	0,0093	<b>0,9561</b>
2070-2080	0,0001	0,0055	0,0073	<b>0,9871</b>
2215-2225	0,0001	0,0019	0,0004	<b>0,9976</b>
<b>2596-2606</b>	0,0153	<b>0,8314</b>	0,0015	0,1518
<b>3012-3052</b>	0,2432	<b>0,7563</b>	0,0002	0,0003

В таблице 4.1,  $Y_1$  – дифференциальный прихват (под действием перепада давления),  $Y_2$  – прихват вследствие геометрических изменений ствола скважины,  $Y_3$  – прихват, вследствие зашламования или закупоривания кольцевого пространства,  $Y_4$  – отсутствие прихвата.

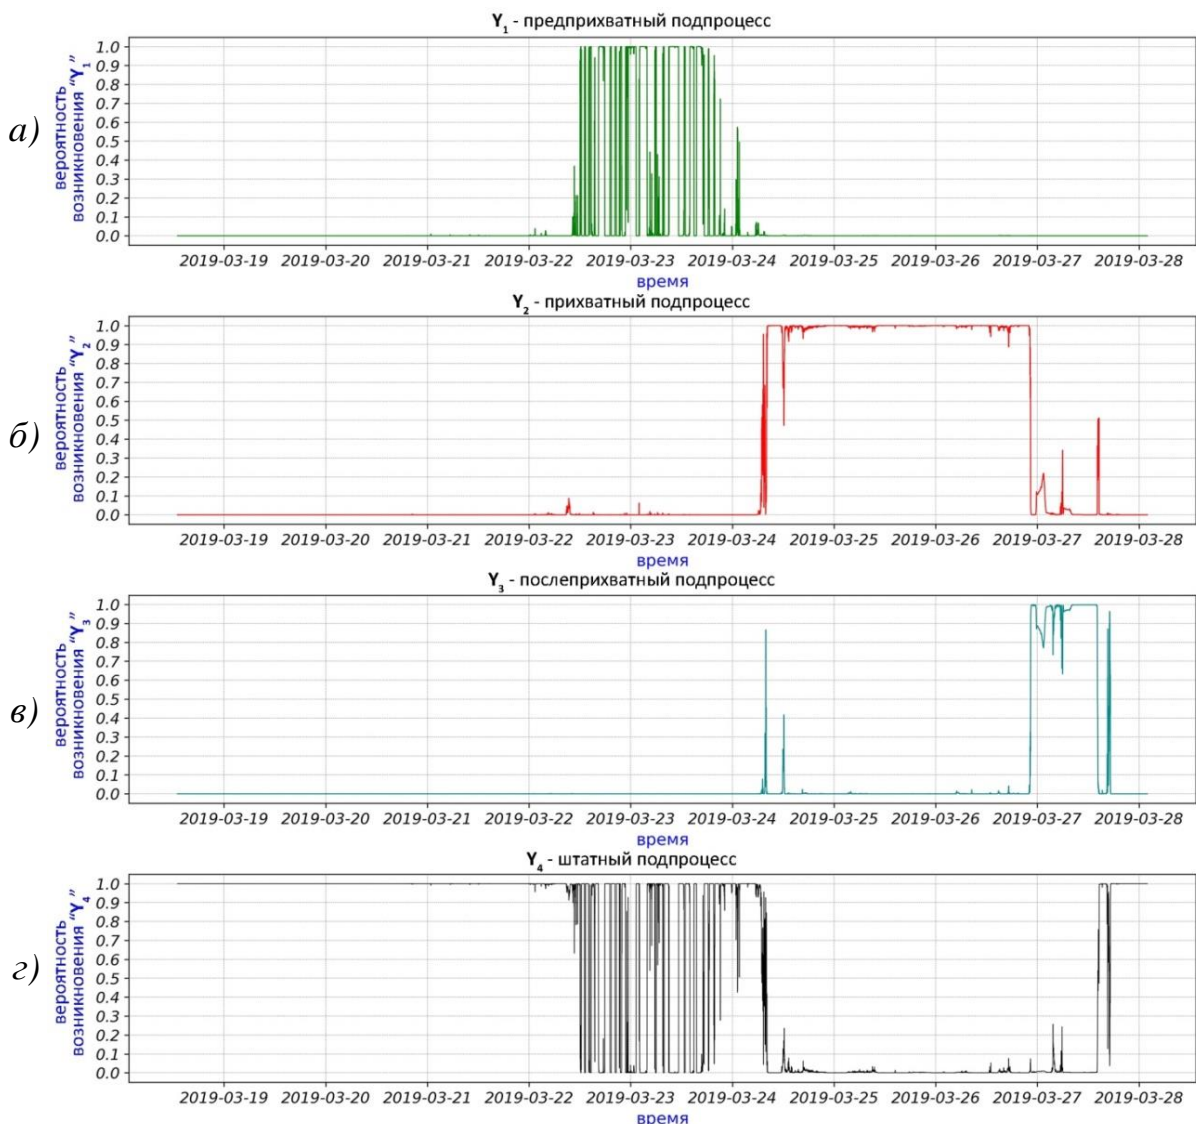
#### **4.2 Анализ результатов прогнозирования прихвата технологического инструмента по глубине ствола скважины**

Как видно из таблицы 4.1, высокая вероятность возникновения прихвата имеется в условиях бурения интервалов 2596-2606 м. и 3012-3052 м. В этих интервалах свойственно произойти прихват ТИ вследствие геометрических изменений ствола скважины. Действительно, в рассматриваемой скважине произошел прихват ТИ на глубине 2660 м. во время спуско-подъемных операций, что является свидетельством возникновения прихвата вследствие геометрических изменений ствола скважины. Что касается расхождения глубины возникновения прихвата на 50 м, то это не критично, если все остальные свойства, параметры и режимы бурения идентичны для рассматриваемого интервала или участка ствола скважины.

### 4.3 Прогнозирование прихвата технологического инструмента по времени бурения

На основе модели и алгоритма прогнозирования прихвата ТИ по времени бурения, также была произведена процедура прогнозирования, в процессах чистого бурения, проработки и промывки ствола скважины, а также спуско-подъемных операций.

В результате процедуры прогнозирования прихвата ТИ по времени бурения, были получены значения вероятностей возникновения по всем четырем подпроцессам ( $Y_1$ ,  $Y_2$ ,  $Y_3$  и  $Y_4$ ), графики которых представлены на рисунке 4.1.

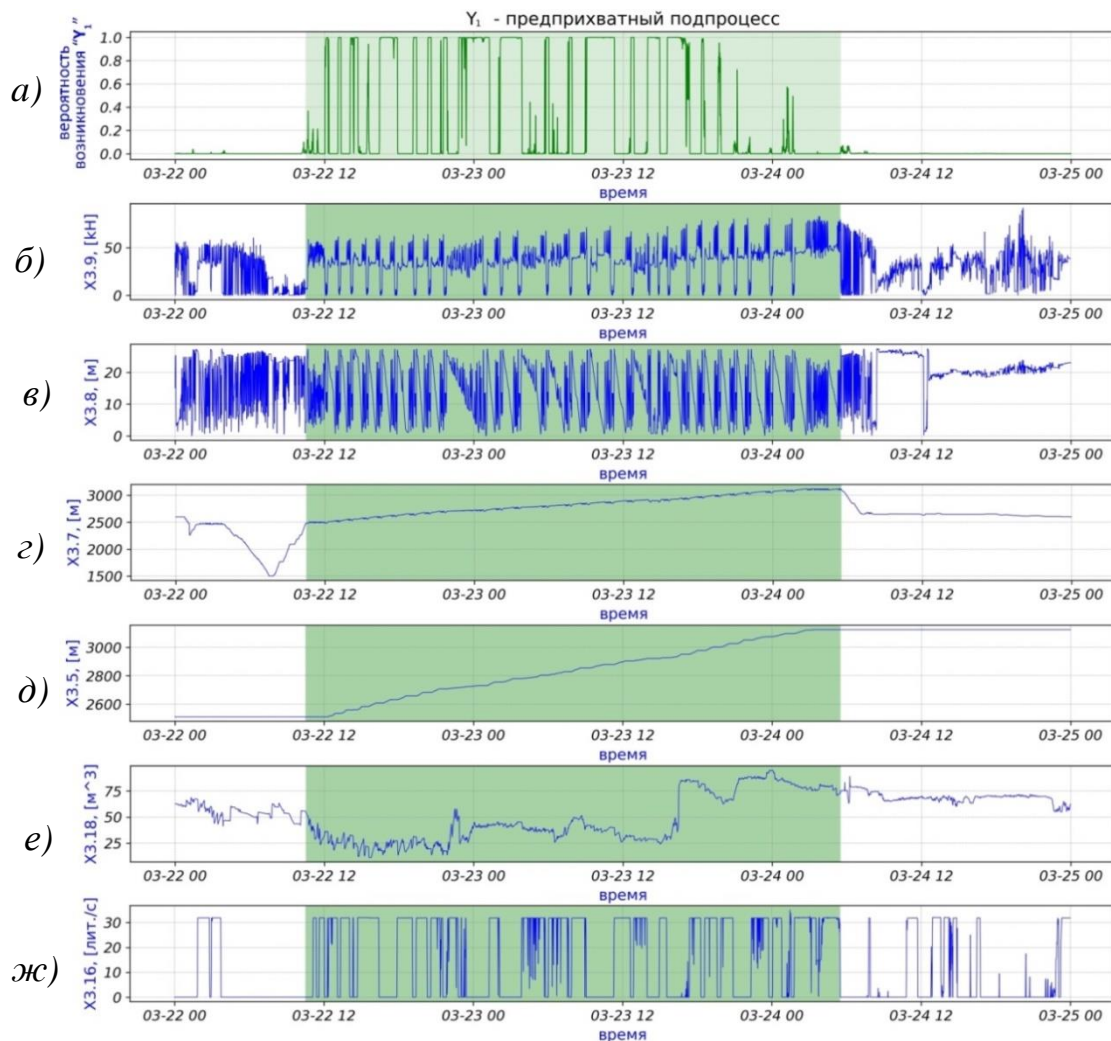


**Рис. 4.1.** Графики вероятностей возникновения а)  $Y_1$  – предприхватного подпроцесса, б)  $Y_2$  – прихватного подпроцесса, в)  $Y_3$  – послеприхватного подпроцесса, а также з)  $Y_4$  – штатного подпроцесса, по времени бурения, в 6-ом рейсе.

Как видно на выше представленных графиках вероятностей возникновения по четырем подпроцессам, каждый подпроцесс возник в разные временные периоды с заимоисключающей последовательностью. Соответственно, произведем последовательный анализ по подпроцессам.

#### 4.4 Анализ результатов прогнозирования прихвата технологического инструмента по времени бурения скважины

$Y_1$  – *предприхватный подпроцесс*. Для удобства интерпретации полученных результатов прогнозирования, сопоставим график вероятности возникновения предприхватного подпроцесса ( $Y_1$ ) с графиками некоторых свойств, параметров и режимов по времени бурения (см. Рис. 4.2).

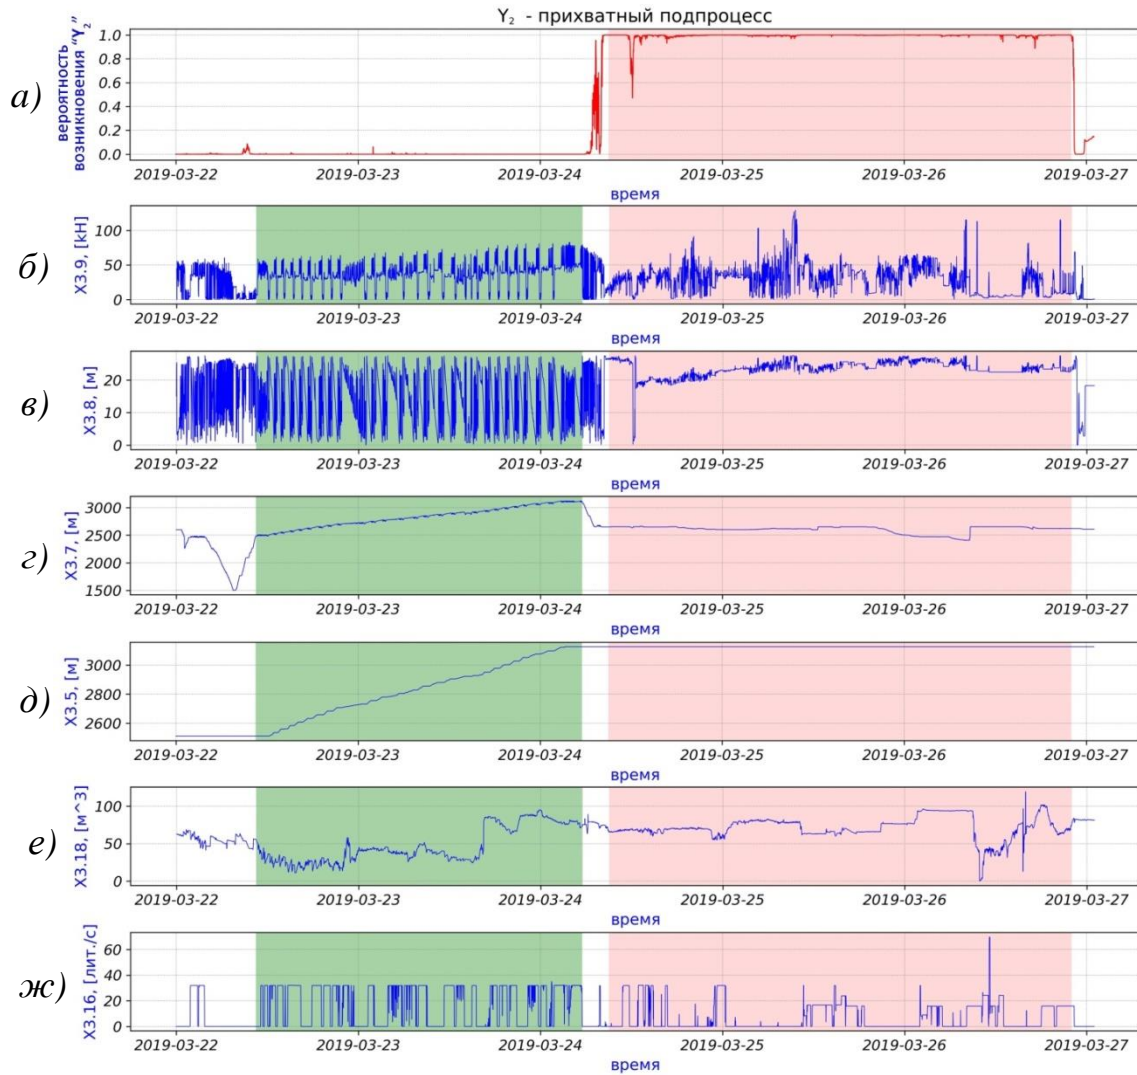


**Рис. 4.2.** Сопоставление графика вероятности возникновения предприхватного подпроцесса ( $Y_1$ ) с графиками свойств, параметров и режимов по времени бурения, в 6-ом рейсе.

На рисунке 4.2, *а)* – график значений вероятности возникновения предприхватного подпроцесса ( $Y_1$ ), *б)* – график значений веса ТИ ( $X_{3.9}$ ), *в)* – график значений положения (высоты) талевого блока ( $X_{3.8}$ ), *г)* – график значений глубины нахождения инструмента ( $X_{3.7}$ ), *д)* – график значений глубины нахождения забоя скважины ( $X_{3.5}$ ), *е)* – график значений суммарного объема бурового раствора в активных (приемных) емкостях ( $X_{3.18}$ ), *ж)* – график значений расхода бурового раствора на входе скважины (Q1) ( $X_{3.16}$ ). Выделенные зеленым, фоном участки графиков – признаки возникновения предприхватного ( $Y_1$ ) подпроцесса.

В результате анализа выше представленных графиков (Рис. 4.2), было установлено, что моделью были обнаружены признаки предприхватного подпроцесса, в промежутке времени, когда велась чистое бурение в интервале 2520 – 3126 м. Признаки предприхватного подпроцесса обусловлена тем, что в интервале 2520 - 3126м. бурения ввелась с недостаточной проработкой и промывкой ствола скважины, а также, с высоким содержанием шлама в буровом растворе. О недостаточной проработки и промывки ствола скважины свидетельствуют графики значений глубины нахождения инструмента (Рис. 4.2, *г)* и расхода бурового раствора на входе скважины (Q1) по времени бурения (Рис. 4.2, *ж)*). А также, о высоком содержании шлама в буровом растворе свидетельствуют графики значений суммарного объема бурового раствора в активных (приемных) емкостях (Рис. 4.2, *е)* и расхода бурового раствора на входе скважины (Q1) по времени бурения (Рис. 4.2, *ж)*). Следовательно, моделью правильно обнаружены признаки предприхватного подпроцесса.

$Y_2$  – *прихватный подпроцесс*. В след за предприхватным подпроцессом, также моделью были обнаружены признаки прихватного подпроцесса (см. Рис. 4.3). Проверка достоверности полученных результатов не составит большого труда, так как признаки прихватного подпроцесса можно заметить по графикам значений веса ТИ (Рис. 4.3, *б)*), положения (высоты) талевого блока (Рис. 4.3, *б)*) и глубины нахождения инструмента по времени бурения (Рис. 4.3, *г)*).



**Рис. 4.3.** Сопоставление графика вероятности возникновения прихватного подпроцесса ( $Y_2$ ) с графиками свойств, параметров и режимов по времени бурения, в 6-ом рейсе.


На рисунке 4.3, *а)* – график значений вероятности возникновения прихватного подпроцесса ( $Y_2$ ), *б)* – график значений веса ТИ ( $X_{3.9}$ ), *в)* – график значений положения (высоты) талевого блока ( $X_{3.8}$ ), *г)* – график значений глубины нахождения инструмента ( $X_{3.7}$ ), *д)* – график значений глубины нахождения забоя скважины ( $X_{3.5}$ ), *е)* – график значений суммарного объема бурового раствора в активных (приемных) емкостях ( $X_{3.18}$ ), *ж)* – график значений расхода бурового раствора на входе скважины ( $Q_1$ ) ( $X_{3.16}$ ). Выделенные зеленым и красным фоном участки графиков – признаки возникновения предприхватного ( $Y_1$ ) и прихватного ( $Y_2$ ) подпроцесса.

Как видно из графиков (см. Рис. 4.3), прихватный подпроцесс возник во время подъема ТИ. Соответственно, сопоставляя график вероятности



возникновения прихватного подпроцесса (Рис. 4.3, а) с графиками значений веса ТИ (Рис. 4.3, б) и положения (высоты) талевого блока по времени бурения (Рис. 4.3, в) не сложно заметить, что моделью была своевременно обнаружена признаки прихватного подпроцесса. Также, следует отметить, что моделью обнаруженные признаки прихватного подпроцесса по продолжительности времени составляет 82 часов. А, в действительности, продолжительность прихватного подпроцесса длилась 81 часов. Это свидетельствует о том, что модель имеет достаточно высокую точность обнаружения прихватного подпроцесса.

$Y_3$  – *послеприхватный подпроцесс*. Признаки послеприхватного подпроцесса, моделью были обнаружены вслед за прихватным подпроцессом (см. Рис. 4.4).



**Рис. 4.4.** Сопоставление графика вероятности возникновения послеприхватного подпроцесса ( $Y_3$ ) с графиками свойств, параметров и режимов по времени бурения, в 6-ом рейсе.

На рисунке 4.4, *а)* – график значений вероятности возникновения послеприхватного подпроцесса ( $Y_3$ ), *б)* – график значений веса ТИ ( $X_{3.9}$ ), *в)* – график значений положения (высоты) талевого блока ( $X_{3.8}$ ), *г)* – график значений глубины нахождения инструмента ( $X_{3.7}$ ), *д)* – график значений глубины нахождения забоя скважины ( $X_{3.5}$ ), *е)* – график значений суммарного объема бурового раствора в активных (приемных) емкостях ( $X_{3.18}$ ). Выделенные красным и синим фоном участки графиков – признаки возникновения прихватного ( $Y_2$ ) и послеприхватного ( $Y_3$ ) подпроцесса.

Соответственно, по результатам анализа графиков (Рис. 4.4, *а* по *е*), было установлено, что моделью верно были обнаружены признаки послеприхватного подпроцесса, которые проявлялись в результате мероприятия по ликвидации прихвата ТИ, например установки нефтяной ванны, оставление в покое ТИ, периодической расхаживанием инструмента и т.п.

Следует отметить, что обнаружение послеприхватного подпроцесса во время бурения скважины, возможно, не имеет такую важность как, например с предприхватным подпроцессом. Но, безусловно имеет большое значение, так как своевременное обнаружение послеприхватного подпроцесса позволит буровому персоналу предпринимать оптимальные меры по ликвидации прихватов.

$Y_4$  – *штатный подпроцесс*. Также моделью были обнаружены признаки штатного подпроцесса, в тех интервалах времени, в которых отсутствовали признаки трех остальных подпроцессов (см. Рис. 4.5).



**Рис. 4.5.** График значений вероятности возникновения штатного подпроцесса ( $Y_4$ ) по времени бурения, в 6-ом рейсе.

Как было отмечено во второй главы данной работы, прихват ТИ по времени бурения условно декомпозируется на четыре подпроцессов, одним из которых является штатный подпроцесс. Штатный подпроцесс, чаще всего носит характер локализации протекающих подпроцессов возникновения прихвата.

Соответственно, моделью полученные значения вероятности возникновения штатного подпроцесса не противоречат реальным произошедшим подпроцессам в рассматриваемой скважине.

#### **4.5 Обобщение полученных результатов прогнозирования прихвата технологического инструмента**

На рассматриваемом примере скважины, по результатам прогнозирования прихвата по двум моделям, было установлено, что прихват произошел по двум взаимосвязанным причинам: 1) некачественная промывка ствола скважины, в том числе накопление шламовой подушки в интервалах ствола скважины с большими зенитными углами; 2) геометрическими изменениями конфигурации ствола скважины, в том числе сужение ствола скважины.

Как показали экспериментальные результаты, модель прогнозирования прихвата ТИ по глубине ствола скважины, позволит 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, позволит обнаруживать признаки предприхватного подпроцесса по времени бурения еще до того как возникнут прихваты. Это позволит на ранних стадиях понять и устранять причины, приводящие к возникновению прихватов.

В заключении, необходимо отметить следующее: модель прогнозирования прихвата ТИ по глубине ствола скважины, спрогнозировала прихват с указанием его типа. Что касается модели прогнозирования прихвата ТИ по времени бурения, то данная модель на примере рассматриваемой скважине тоже обнаружила признаки предприхватного подпроцесса до того как возник прихват. Данная модель не дублирует функциональность модели по глубине ствола скважины, а наоборот, является дополнением в расширение функциональности, так как учитывает динамику изменения множество свойств, параметров и режимов бурения. А также модель по времени бурения способна учитывать человеческие факторы и причины, влияющие на процесс возникновения прихвата, например, высокая скорость спуско-подъемных операций, оставление ТИ без вращения в зоне открытого ствола скважины и т.п.



#### 4.6 ВЫВОДЫ ПО ГЛАВЕ 4

В данной главе, продемонстрирована целесообразность применения двух моделей прогнозирования прихвата ТИ. Первая модель позволила обнаруживать прихват по глубине ствола скважины на стадии проектирования и в процессе бурения, учитывая данные о параметрах скважины и бурения, большинство из которых являются факторами возникновения прихвата. Вторая модель, учитывая технико-технологические факторы прихвата, позволила прогнозировать прихват по времени бурения скважины на основе свойств, параметров и режимов бурения. Так как признаки возникновения прихвата можно характеризовать изменениями значений свойств, параметров и режимов бурения, то соответственно, первая модель позволяет прогнозировать прихват на факторах, а вторая модель учитывает факторы, но прогнозирует прихват по признакам и причинам их возникновения.

Следует отметить, что для того чтобы установить причины возникновения предприхватного подпроцесса, необходимо сопоставить результаты полученных прогнозов с графиками свойств, параметров и режимов бурения. В свою очередь, как показали экспериментальные результаты, объединяя полученные прогнозы первой модели со второй, можно оперативно установить причины возникновения предприхватного подпроцесса, чтобы предпринимать меры по их устранению. Следовательно, обобщение результатов прогнозирования двух моделей, позволит оперативно установить причины возникновения предприхватного подпроцесса, а также уменьшить риски возникновения непредвиденных прихватов.

## 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, учитывающий 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 демонстрировала 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.

**БИБЛИОГРАФИЧЕСКИЙ СПИСОК**

1. Липатов, Е.Ю. Исследование и разработка технологии и технических средств для предупреждения и ликвидации прихвата бурильной колонны (на примере месторождений Среднего Приобья): монография / Е.Ю. Липатов. Тюмень: ТюмГНГУ, 2015. – 128 с.
2. Mohiuddin, M.A. Analysis of wellbore instability in vertical, directional and horizontal wells using field data / M.A. Mohiuddin, K. Khan, A. Abdulraheem, A. Al-Majed, M.R. Awal / Journal of Petroleum Science and Engineering. – 2007. – №55. – P. 83–92.
3. Muqem, M.A., Weekse, A.E., Al-Hajji, A.A. Stuck Pipe Best Practices - A Challenging Approach to Reducing Stuck Pipe Costs. Presented at the SPE Saudi Arabia Section Technical Symposium and Exhibition, Al-Khobar, Saudi Arabia. – 2012. – 10 p.
4. Al-Dossary, A. New Offshore Sidetrack Practices Reduced Significantly Stuck Pipes in KSA // Paper presented at the International Petroleum Technology Conference, Beijing, China. – 2013. – 12 p.
5. Abd Elsalam, H., ElNady, Y., Elfakharany, T. Dahab, A.S. Systemic approach to minimize stuck pipe incidents in oil wells // Journal of Al Azhar University Engineering Sector. – 2016. – Vol. 11, №38. – P. 255-264.
6. Abbas, R., Gerhard, T., Mehran, M., Khalil, S., Rahman, A., Abbas, Z., Asad, E. An Investigation of Stuck Pipe Occurrences in Iran // International Journal of Scientific & Engineering Research. – 2016. – Vol. 7, Issue 3. – 6 p.
7. Aljubran, M.J., Al-Yami, A.S., Madan, M.A. Best Practices to Prevent Stuck Pipe Incidents in Offshore Shaly Formations // Paper presented at the SPE Middle East Oil & Gas Show and Conference, Manama, Kingdom of Bahrain. – 2017. – 14 p.
8. Alshaikh, A.A., Amanullah, Md. A Comprehensive Review of Differential Sticking, Spotting Fluids, and the Current Testing and Evaluation Methods // Paper presented at the SPE Kingdom of Saudi Arabia Annual Technical Symposium and Exhibition, Dammam, Saudi Arabia. – 2018. – 12 p.
9. Alhamed, H., Alshaarawi, A., Albadran, M., Meshari, A. Stuck Pipe Mitigating During Drill Pipe Connection Using Rotation Continuous Circulation Tool // Paper presented at the International Petroleum Technology Conference, Dhahran, Kingdom of Saudi Arabia. – 2020. – 5 p.
10. Alshaikh, A.A., Albassam, M.K., Al Gharbi, S.H., & Al-Yami, A.S. Detection of Stuck Pipe Early Signs and the Way Toward Automation. Society of Petroleum Engineers. – 2018. – 10 p.

11. Skalle, P., Aamodt, A., Sveen, J. Case-based Reasoning, a Method for Gaining Experience and Giving Advice on How to Avoid and How to Free Stuck Drill Strings // IADC Middle East Drilling Conference, Dubai. – 1998. – 12 p.
12. Meschi, M.R., Shahbazi, K., and Pordel S.M. A New Criteria to Predict Stuck Pipe Occurrence // Paper presented at the North Africa Technical Conference and Exhibition, Cairo, Egypt. – 2010. – 9 p.
13. Shahbazi, K., Shahri, M.P. The development of a window for stuck pipe prediction // Petroleum Science and Technology. – 2012. Vol. 30, Issue 2. – P. 176-192.
14. Eren, T., Azeez, M., and Tawfeeq, B.A. Stuck Pipe Prevention While Drilling Wells to Limestone & Sandstone Reservoirs – Southern Iraq // Second International Conference on Water, Energy and the Environment, Kusadasi. – 2013. –P. 1-8.
15. Eren, T. Stuck Pipe Incidents in Middle East Wells Drilled to Limestone and Sandstone Reservoirs // Dokuz Eylul University-Faculty of Engineering, Journal of Science and Engineering. – 2018. – Vol. 20, Issue 59. – 13 p.
16. Самотой, А.К. Предупреждение и ликвидация прихватов труб при бурении скважин: учебное пособие / А.К. Самотой. М.: Недра, 1979. – 182 с.
17. Самотой, А.К., Воротнюк, О.В. Анализ априорных данных о факторах, действующих при прихвате колонны труб // Тр. ВНИИБТ. Борьба с осложнениями при бурении скважин. – 1973. – Вып. 7. – С. 25-32.
18. Аветисов, А.Г., Ахмадуллин, М.М., Самотой, А.К. Прогнозирование, предупреждение и ликвидация прихватов с использованием статистических методов // Тематический научно-технический обзор. М.: ВНИИОЭНГ. – 1977. – С. 62-73.
19. Аветисов, А.Г., Ахмадуллин, М.М., Кошелев, Н.Н. Методическое руководство по распознаванию, прогнозированию и предупреждению прихватов колонн труб методом последовательной диагностической процедуры / А.Г. Аветисов, М.М. Ахмадуллин, Н.Н. Кошелев и др. Краснодар, ВНИИКРнефть, 1977. – 75 с.
20. Мирзаджанзаде, А.Х., Булатов, А.И., Аветисов, А.Г. Методическое руководство по применению методов распознавания образов при промывке и креплении скважин / А.Х. Мирзаджанзаде, А.И. Булатов, А.Г. Аветисов и др. Краснодар, 1974. – 65 с.
21. Мирзаджанзаде, А.Х., Аветисов, А.Г., Булатов, А.И. Методические указания по применению статистических методов в бурении нефтяных и газовых скважин / А.Х. Мирзаджанзаде, А.Г. Аветисов, А.И. Булатов и др. – Краснодар, 1983. – 72 с.

22. Hempkins, W.B., Kingsborough, R.H., Lohec, W.E., & Nini, C.J. Multivariate Statistical Analysis of Stuck Drillpipe Situations. Society of Petroleum Engineers. – 1987. – 8 p.
23. Biegler, M.W., Kuhn, G.R. Advances in Prediction of Stuck Pipe Using Multivariate Statistical Analysis. Society of Petroleum Engineers. – 1994. – 14 p.
24. Howard, J.A., Glover, S.B. Tracking Stuck Pipe Probability While Drilling. Society of Petroleum Engineers. – 1994. – 10 p.
25. Shoraka, S.A.R., Shadizadeh, S.R., Shahri, M.P. Prediction of Stuck Pipe in Iranian South Oil Fields Using Multivariate Statistical Analysis. Society of Petroleum Engineers. – 2011. – 10 p.
26. Siruvuri, C., Nagarakanti, S. & Samuel R. Stuck pipe prediction and avoidance: a convolution neural network approach // IADC/SPE Drilling Conference, Miami, Florida, USA. – 2006. – P. 1-6.
27. Miri, R., Sampaio, J.H.B., Afshar, M., Lourenco, A. Development of Artificial Neural Networks to Predict Differential Pipe Sticking in Iranian Offshore Oil Fields. Society of Petroleum Engineers. – 2007. – 15 p.
28. Jahanbakhshi, R., Keshavarzi, R., Jahanbakhshi, R. Intelligent Prediction of Wellbore Stability In Oil And Gas Wells: An Artificial Neural Network Approach. Presented at the 46th U.S. Rock Mechanics/Geomechanics Symposium, Chicago, Illinois. – 2012. – 9 p.
29. Murillo, A., Neuman, J., Samuel, R. Pipe sticking prediction and avoidance using adaptive fuzzy logic and neural network modeling. Paper presented at Production and Operations Symposium held in Oklahoma City, Oklahoma, USA. – 2009. – 15 p.
30. Heinze, L., Al-Baiyat, I.A. Implementing Artificial Neural Networks and Support Vector Machines in Stuck Pipe Prediction. Society of Petroleum Engineers. Kuwait. – 2012. – 13 p.
31. Chamkalani, A., Pordel Shahri, M., Poordad, S. Support Vector Machine Model: A New Methodology for Stuck Pipe Prediction. Society of Petroleum Engineers. Oman. – 2013. – 13 p.
32. Morteza, E.N., Peyman, E., Saeid, J. Prediction of drilling pipe sticking by active learning method (ALM) // Academic Journals. Journal of Petroleum and Gas Engineering. – 2013. – Vol. 4(7). – P. 173-183.
33. Abbas, Ahmed K., Flori, R., Almubarak, H., Dawood, J., Abbas, H., and Ahmed A. Intelligent Prediction of Stuck Pipe Remediation Using Machine Learning

- Algorithms // Paper presented at the SPE Annual Technical Conference and Exhibition, Calgary, Alberta, Canada. – 2019. – 15 p.
34. Abbas, Ahmed K., Almubarak, H., Abbas, H., and Jawad D. Application of Machine Learning Approach for Intelligent Prediction of Pipe Sticking // Paper presented at the Abu Dhabi International Petroleum Exhibition & Conference, Abu Dhabi, UAE. – 2019. – 14 p.
  35. Zhu, Q., Wang, Z., Jian, H. Stuck Pipe Incidents Prediction Based On Data Analysis // Paper presented at the SPE Gas & Oil Technology Showcase and Conference, Dubai, UAE. – 2019. – 10 p.
  36. Абу-Абед, Ф.Н. Надежность объектов нефтегазодобывающей промышленности // Газовая промышленность. – 2015. – № S720 (720). – С. 107-111.
  37. Абу-Абед, Ф.Н. Автоматизированная система обнаружения предаварийных ситуаций на объектах нефтегазодобывающей промышленности // Каротажник. – 2015. – № 5 (251). – С. 48-61.
  38. Абу-Абед, Ф.Н. Снижение риска при строительстве газовых скважин на базе нейросетевой модели // Газовая промышленность. – 2014. – № S712 (712). – С. 100-102.
  39. Абу-Абед, Ф.Н. Обнаружение предаварийных ситуаций в процессе промышленного бурения нефтяных скважин: кан. диссертация / Ф.Н. Абу-Абед. Тверь, 2011. – 206 с.
  40. Абу-Абед, Ф.Н., Допира, Р.В. Применение средств моделирования нейросетей для анализа предаварийных ситуаций на буровых // Программные продукты и системы. – 2010. – № 3. – С. 136-139.
  41. Borozdin, S., Dmitrievsky, A., Eremin, N., Arkhipov, A., Sboev, A., Chashchina-Semenova, O., Fitzner, L., and Safarova E. Drilling Problems Forecast System Based on Neural Network // Paper presented at the SPE Annual Caspian Technical Conference. – 2020. – 16 p.
  42. Еремин, Н.А. , Черников, А.Д., Сарданашвили, О.Н, Столяров, В.Е., Архипов, А.И. Цифровые технологии строительства скважин. Создание высокопроизводительной автоматизированной системы предотвращения осложнений и аварийных ситуаций в процессе строительства нефтяных и газовых скважин // Деловой журнал Neftegaz.Ru. – 2020. – № 4 (100). – С. 38–50.
  43. Патент на изобретение Автоматизированная система выявления и прогнозирования осложнений в процессе строительства нефтяных и газовых

скважин /Дмитриевский А.Н., Еремин Н.А., Чащина- Семенова О.К., Фицнер Л.К., Черников А.Д. – Заявка № 2020129673/03 (053361) от 08.09.2020.

44. Автоматизированная система выявления и прогнозирования осложнений в процессе строительства нефтяных и газовых скважин // А.Н. Дмитриевский, Н.А. Еремин, О.К. Чащина-Семенова, Л.К. Фицнер, А.Д. Черников Патент на полезную модель RU. Заявка № 2020129673/03 (053361) от 08.09.2020.
45. Дмитриевский, А.Н., Еремин, Н.А., Чащина-Семенова, О.К., Фицнер, Л.К., Черников, А.Д. Автоматизированная система выявления и прогнозирования осложнений в процессе строительства нефтяных и газовых скважин // Патент на полезную модель RU. Заявка № 2020129671/03 (053358) от 08.09.2020.
46. Sadlier, A., Says, I., Hanson, R. Automated Decision Support to Enhance While-Drilling Decision Making: Where Does it fit Within Drilling Automation? // Society of Petroleum Engineers. – 2013. – 8 p.
47. Ferreira, A.P.L.A., Carvalho, D.J.L., Rodrigues, R.M., Schnell, D.M., Thomson, I.J., Baptista, R.C., Alves, S.B. Automated Decision Support and Expert Collaboration Avoid Stuck Pipe and Improve Drilling Operations in Offshore Brazil Subsalt Well // Offshore Technology Conference. – 2015. – 10 p.
48. Salminen, K., Cheatham, C., Smith, M., Valiullin, K. Stuck Pipe Prediction Using Automated Real-Time Modeling and Data Analysis // Paper presented at the IADC/SPE Drilling Conference and Exhibition, Fort Worth, Texas, USA. – 2016. – 20 p.
49. Salminen, K., Cheatham, C., Smith, M., Valiullin, K. Stuck-Pipe Prediction by Use of Automated Real-Time Modeling and Data Analysis // SPE Drill & Compl. – 2017. – Vol. 32. – P. 184–193.
50. Hess, J. Pipe Sticking Prediction Using LWD Real-Time Measurements // Society of Petroleum Engineers. 2016. 15 p. doi:10.2118/178828-MS.
51. Magana-Mora, A., Gharbi, S., Alshaikh, A., and Abdullah A.Y. AccuPipePred: A Framework for the Accurate and Early Detection of Stuck Pipe for Real-Time Drilling Operations // Paper presented at the SPE Middle East Oil and Gas Show and Conference, Manama, Bahrain. – 2019. – 10 p.
52. Alshaikh, A., Magana-Mora, A., Gharbi, S.A., and Abdullah A.Y. Machine Learning for Detecting Stuck Pipe Incidents: Data Analytics and Models Evaluation // Paper presented at the International Petroleum Technology Conference, Beijing, China. – 2019. – 9 p.
53. Ahmed, O.S., Aman, B.M, Zahrani, M.A., and Folorunsho, I.A. Stuck Pipe Early Warning System Utilizing Moving Window Machine Learning Approach // Paper



- presented at the Abu Dhabi International Petroleum Exhibition & Conference, Abu Dhabi, UAE. – 2019. – 15 p.
54. Spivey, B., Bailey, J., Pokluda, J., and Coby, P. Data Driven Methods to Monitor Sticking Friction While Running Pipe // Paper presented at the SPE Annual Technical Conference and Exhibition, Calgary, Alberta, Canada. – 2019. – 11 p.
  55. Zhang, F., Islam, A., Zeng, H., Chen, Z., Zeng, Y., Wang, X., and Siyang, L. Real Time Stuck Pipe Prediction by Using a Combination of Physics-Based Model and Data Analytics Approach // Paper presented at the Abu Dhabi International Petroleum Exhibition & Conference, Abu Dhabi, UAE. – 2019. – 16 p.
  56. Nakagawa, Y., Inoue, T., Bilen, H., Mopuri, K.R., Miyoshi, K., Abe3, S., Wada, R., Kuroda, K., and Hitoshi T. An Unsupervised Learning Model for Pipe Stuck Predictions Using a Long Short-Term Memory Autoencoder Architecture // Paper presented at the SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition. – 2021. – 9 p.
  57. Konda, R.M., Hakan, B., Naoki T., Ryota W., Tomoya I., Kazuya K., Tazuru N., Hitoshi T. Early sign detection for the stuck pipe scenarios using unsupervised deep learning // Journal of Petroleum Science and Engineering. – 2022. – Vol. 208, Part C. – 12 p.
  58. Toreifi, H., Rostami, H. Manshad, A.K. New method for prediction and solving the problem of drilling fluid loss using modular neural network and particle swarm optimization algorithm // J Petrol Explor Prod Technol. – 2014. – Vol. 4. – P. 371–379.
  59. Melin, P. Modular Neural Networks and Type-2 Fuzzy Systems for Pattern Recognition // Studies in Computational Intelligence, Springer-Verlag Berlin Heidelberg. – 2012. – Vol. 389. – 215 p.
  60. Melin, P., Castillo, O., Kacprzyk, J. Design of Intelligent Systems Based on Fuzzy Logic, Neural Networks and Nature-Inspired Optimization // Studies in Computational Intelligence, Springer International Publishing Switzerland. – 2015. – Vol. 601. – 612 p.
  61. Gutiérrez, L., Melin, P., López, M. Modular Neural Network for Human Recognition from Ear Images Using Wavelets. In: Melin P., Kacprzyk J., Pedrycz W. (eds) Soft Computing for Recognition Based on Biometrics. Studies in Computational Intelligence. Springer, Berlin, Heidelberg. – 2010. – Vol. 312. – 15 p.
  62. Shukla, A., Tiwari R., Kala R. Modular Neural Networks. In: Towards Hybrid and Adaptive Computing. Studies in Computational Intelligence. Springer, Berlin, Heidelberg. – 2010. – Vol. 307. – P. 30-335.

63. Rojas, R. Modular Neural Networks. In: Neural Networks. Springer, Berlin, Heidelberg. – 1994. – P. 1-15.
64. Patil, C., Salmalge S., Nartam P. Cyberbullying Detection on Multiple SMPs Using Modular Neural Network. In: Gunjan V., Senatore S., Kumar A., Gao XZ., Merugu S. (eds) Advances in Cybernetics, Cognition, and Machine Learning for Communication Technologies. Lecture Notes in Electrical Engineering. Springer, Singapore. – 2012. – Vol. 643. – P. 285-298.
65. Happel, B.L.M., Murre, J.M.J.: The Design and Evolution of Modular Neural Network Architectures. Neural Netw. – 1994. – Vol. 7. – 15 p.
66. Bart L.M. Happel, Jacob M.J. Murre. Design and evolution of modular neural network architectures. Neural Networks. – 1994. – Vol. 7, Issues 6–7. – P. 985-1004.
67. Заливин, В.Г. Аварийные ситуации в бурении на нефть и газ / В.Г. Заливин, А.Г. Вахромеев. Вологда: "Инфра-Инженерия", 2018. – 508 с.
68. Ясов, В.Г., Мыслюк, М.А. Осложнения в бурении: справочное пособие / В.Г. Ясов, М.А. Мыслюк. М.: Недра, 1991. – 334 с.
69. Гончаров, А.Е., Винниченко, В.М. Пособие бурильщику и мастеру по предупреждению и ликвидации аварий и осложнений при разведочном бурении. М.: Недра, 1987. –128 с.
70. Пустовойтенко, И.П., Сельващук, А.П. Справочник мастера по сложным буровым работам: справочное пособие / И.П. Пустовойтенко, А.П. Сельващук. М.: Недра, 1983. – 283 с.
71. Bowes, C., Procter, R., Forex, S. Drillers Stuck pipe: Handbook / C. Bowes, R. Procter, S. Forex. Ballater, Scotland: Schlumberger, 1997. – 71 p.
72. Mitchell, J. Trouble-Free Drilling: Stuck Pipe Prevention, second edition / John Mitchell. The Woodlands, TX: Drilbert Engineering, 2011. 280 p.
73. Billy, A.O. Analysis of stuck pipe incidents in Menengai: Geothermal Development Company – GDC. UNU-GTP. – 2014. – №27. – P. 567-593.
74. Лукьянов, Э.Е., Стрельченко, В.В. Геолого-технологические исследования в процессе бурения - М.: Нефть и газ, 1997. – 688 с.
75. Лукьянов, Э.Е. Исследования скважин в процессе бурения. Москва.: Недра, 1979. –248с.
76. Лукьянов, Э.Е., Стрельченко, В.В. Геолого-технологические исследования в процессе бурения - М.: Нефть и газ, 1997. – 688 с.

77. Лукьянов, Э.Е. Исследования скважин в процессе бурения. Москва.: Недра, 1979. –248с.
78. 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.
79. 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 ; опубл. 09.11.2020, Бюл. № 31.
80. 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.
81. Анфилатов, С.В., Емельянов, А.А., Кукушкин, А.А. Системный анализ в управлении. - М.: Финансы и статистика, 2002. – 368 с.
82. Перегудов, Ф.И., Тарасенко, Ф.П. Введение в системный анализ. – М.: Высшая школа, 1989. – 360 с.
83. Гайдышев, И. Анализ и обработка данных. – СПб: Питер, 2001. – 752 с.
84. Волковой, В.Н., Козлова, В.Н. Системный анализ и принятие решений. – М.: Высшая школа, 2001. – 616 с.
85. Чернышев, В.Н., Чернышев, А.В. Теория систем и системный анализ: уч. пособие. – Тамбов: Изд-во Тамб. гос. техн. ун-та, 2008. – 96 с.
86. Клигер, С.А, Косолапов, М.С., Толстова, Ю.Н. Шкалирование при сборе и анализе социологической информации. Монография. – М.: Издательство «Наука», 1978. – 176 с.
87. Кошелева, Н.Н. Корреляционный анализ и его применение для подсчета ранговой корреляции Спирмена / Н.Н. Кошелева // Актуальные проблемы гуманитарных и естественных наук. –2012. – № 5. – С. 23–26.
88. Qodirov, Sh.Sh., Shestakov, A.L. Development of Artificial Neural Network for Predicting Drill Pipe Sticking in Real-Time Well Drilling Process // 2020 Global Smart Industry Conference (GloSIC2020). – 2020. – P. 139-144.
89. 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.
90. Способ прогнозирования прихватов бурильных труб в процессе бурения скважины в режиме реального времени : пат. №2753289 Российска Федерация : МПК E21B44/00 G06N3/08 / А.Л. Шестаков (RU), Ш.Ш. Кодиров (TJ) ; ФГАОУ ВО «ЮУрГУ (НИУ)» ; Патентный отдел. — №2020134345/03 ; опубл. 12.08.2021, Бюл. № 23.
91. Хайкин, С. Нейронные сети: полный курс / Саймон Хайкин. М: Издательский дом «Вильямс», 2006. – 1104 с.
92. Головкин, В.А. Нейросетевые технологии обработки данных : учеб. пособие / В. А. Головкин, В. В. Краснопрошин. – Минск: БГУ, 2017. – 263 с.
93. Шолле, Ф. Глубокое обучение на Python: справочное пособие / Ф. Шолле. СПб.: Питер, 2018. — 400 с.
94. Andreas, F.V. Industrial Machine Learning: Using Artificial Intelligence as a Transformational Disruptor. Apress, Berkeley, CA. 2020. – 664 p.
95. Gulli, A. Deep Learning with Keras: hand book / Antonio Gulli, Sujit Pal. BIRMINGHAM – MUMBAI: Packt, 2017. - 310 p.
96. Рашка, С. Python и машинное обучение: справочное пособие / С. Рашка. М.: ДМК Пресс, 2017. - 418 с.
97. Грас, Дж. Наука о данных с нуля: учебное пособие / Дж. Грас. СПб.: БХВ-Петербург, 2017. – 336 с.
98. Jojo, M. Learn Keras for Deep Neural Networks: hand book / M. Jojo. Canada: Apress, 2019. – 192 p.
99. Ketkar, N. Deep Learning with Python: A Hands-on Introduction / N. Ketkar. India: Apress, 2017. – 162 p.
100. Wani M.A., Bhat F.A., Afzal S., Khan A.I. Advances in Deep Learning. Studies in Big Data. Springer Singapore. – 2020. – Vol. 57. – 159 p.
101. Макмахан Б., Знакомство с PyTorch: глубокое обучение при обработке естественного языка / Б. Макмахан, Д. Рао. СПб.: Питер, 2020. – 256с.
102. Дам Ван Ньить. Нейросетевые технологии в задаче автоматического распознавания видов цифровой модуляции: кан.диссертация. Москва, 2018. – 159 с.
103. Nasiriany, S. A Comprehensive Guide to Machine Learning / S. Nasiriany, G. Thomas, W. Wang, A. Yang, J. Listgarten, A. Sahai // Department of Electrical

- Engineering and Computer Sciences University of California. Berkeley, 2019. – 185 p.
104. Glorot, X. Bengio, Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks. Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics. Proceedings of Machine Learning Research, – 2010. – Vol. 9. – P. 249-256.
  105. Srivastava, N., Hinton, G.E., Krizhevsky, A., Sutskever, I., and Salakhutdinov, R. Dropout: a simple way to prevent neural networks from overfitting. Journal of Machine Learning Research. – 2014. – Vol. 15, № 1. – P. 1929–1958.
  106. Labach, A., Salehinejad, H., Valaee, Sh. Survey of Dropout Methods for Deep Neural Networks. arXiv preprint. – 2019. – 11 p.
  107. Baldi, P., Sadowski, P. J. Understanding Dropout. Advances in Neural Information Processing Systems 26 (NIPS 2013). – 2013. – 9 p.
  108. Нгуен, А. Т. Алгоритмическое обеспечение нейронной сети с полиномиальными кусочно-непрерывными функциями активации для обнаружения закономерностей в данных: кан.диссертация. Томск, 2019. – 112 с.
  109. Peter, J. B., Richard, A. D. Introduction to Time Series and Forecasting. Springer International Publishing Switzerland. – 2016. – 428 p.
  110. Plummer, E. A. Time series forecasting with feed-forward neural networks: guidelines and limitations: Thesis Master of Science / Plummer Eric A. – 2000. – 60 p.
  111. Mozaffari, L. Vehicle speed prediction via a sliding-window time series analysis and an evolutionary least learning machine: A case study on San Francisco urban roads / L. Mozaffari, A. Moxaffari, N. L. Azad // Engineering science and technology, an international journal. – 2015. – Vol. 18. – P. 150-162.
  112. Vafaeipour, M. Application of sliding window technique for prediction of wind velocity time series / M. Vafaeipour, O. Rahbari, M. A. Rosen, F. Fazelpour, P. Ansarirad // International journal of Energy and environmental engineering (springer). –2014. – Vol. 5. – P. 105-111.
  113. Jason, B. Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python. Jason Brownlee, 2018. – 574 p.
  114. Adrian, R. Deep Learning for Computer Vision with Python. PYIMAGESEARCH, 2017. – 332 p.

115. Le, T. A. Deep neural network models for sequence labeling and coreference tasks: candidate dissertation. Dolgoprudny, 2020. – 143 p.
116. Francesca, L. Machine Learning for Time Series Forecasting with Python. John Wiley & Sons, Inc., Canada, 2021. – 216 p.
117. Burkov, A. Machine Learning Engineering. Draft, 2021. – 274 p.

## ПРИЛОЖЕНИЕ А

**Таблица 1.1.** Методы распознавания и прогнозирования прихвата ТИ [10, 16-57].

Литература	Кол.-во эл.-ов входных данных	Вид и количество выходной информации	Применяемые алгоритмы	Метрика оценки качества прогнозирования
<b>Методы распознавания и прогнозирования прихвата ТИ по глубине ствола скважины</b>				
[16-21]	18	классификация на 3 групп прихват	метод максимального правдоподобия	ACC = 0,70-0,90
[22, 23]	20	классификация на 3 группы: механический прихват; дифференциальный прихват; отсутствие прихват.	многофакторный дискриминантный анализ	ACC = 0,81-0,87
[24]	40			
[25]	24			
[26]	10	классификация на 2 группы: прихват и отсутствие прихвата.	одномерная свёрточная нейронная сеть	ACC = 0,90
[27]	9		многослойная полносвязанная нейронная сеть	ACC = 0,9286
[28]	12		радиально базисная нейронная сеть	ACC = 0,919
[29]	18	классификация на 3 группы: механический прихват; дифференциальный прихват; отсутствие прихват.	адаптивная нечеткая логики и полносвязанная нейронная сеть	ACC = 0,984
[30]			полносвязанная нейронная сеть и метод опорных векторов	ACC = 1,0
[31]	22		машина опорных векторов наименьших квадратов	ACC = 0,960
[32]	7	классификация на 2 группы: прихват и отсутствие прихвата.	нечеткая логика и алгоритм активного обучения	ACC = 1,0
[33-34]	20	классификация на 5 групп события.	полносвязанная нейронная сеть и метод опорных векторов	ACC = 0,90
[35]	20	-	полносвязанная нейронная сеть	-
<b>Методы распознавания и прогнозирования прихвата ТИ по времени бурения скважины</b>				
[36-40]	21	классификация на аварийной и штатной ситуации	кластерный анализ и полносвязанная нейронная сеть	ACC = 0,96
[41-45]	8	классификация на 3 группы: газонефтеводопроявление; поглощение; прихват бурильной колонны.	полносвязанная нейронная сеть	ACC = 0,87
[46-47]	-	-	-	-
[48-49]	7	классификация на 2 группы: прихват и отсутствие прихвата.	классические методы анализ временных рядов	-
[50]	39	классификация на 2 группы: прихват и отсутствие прихвата.	линейная регрессионная модель	-
[10]	10	Индекс риска возникновения прихват, от 0 до 100%	алгоритм машинного обучения	ACC = 0,90
[51]	14	классификация на 2 группы: прихват и отсутствие прихвата.	случайный лес, метод опорных векторов и полносвязанная нейронная сеть	ACC = 0,83-0,92
[52]	13			
[53]	11	классификация на 2 группы: максимальный и минимальный риск возникновения прихват.	алгоритмы машинного обучения с применением метода скользящего окна	ACC = 0,67-0,80
[54]	4	Индекс риска возникновения прихват, от 0 до 100%	классические методы анализ временных рядов	ACC = 0,98
[55]	7	Индекс риска возникновения прихват, от 0 до 100%	классические методы анализ временных рядов	-
[56-57]	13	Индекс ошибки энкодера	сети долгой краткосрочной памяти с автоэнкодером (LSTM-AE)	-

## ПРИЛОЖЕНИЕ Б

**Таблица 2.1. Классификация прихватов по механизмам, факторам, причинам и признакам их возникновения [1, 7-14]**

Механизмы возникновения прихват	Причины возникновения прихват	Факторы, влияющие на процесс возникновения прихват	Характерные признаки прихвата	
1	2	3	4	
<b>Механический прихват</b>	<b>Прихват в следствие зашламование или закупоривание кольцевого пространства твердыми частицами</b>	Некачественная промывка кольцевого пространства ствола скважины	<ul style="list-style-type: none"> <li>- скорость потока промывочной жидкости;</li> <li>- реологические свойства и технологические параметры бурового раствора;</li> <li>- частота вращения бурильной колонны;</li> <li>- наружный диаметр долота;</li> <li>- зенитный угол ствола скважины;</li> <li>- механическая скорость бурения;</li> </ul>	<ul style="list-style-type: none"> <li>- увеличение крутящего момента и осевых нагрузок во время бурения;</li> <li>- снижение выхода шлама на виброситах;</li> <li>- увеличение давления в нагнетательной линии;</li> <li>- посадка инструмента или плохая передача нагрузки на долото;</li> <li>- увеличение веса при подъеме колонны;</li> <li>- повторное перемалывание шлама;</li> </ul>
		Коагуляция промывочной жидкости	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- температура забоя скважины;</li> <li>- скорость потока промывочной жидкости;</li> <li>- реологические свойства и технологические параметры бурового раствора;</li> <li>- температура бурового раствора;</li> <li>- частота вращения бурильной колонны;</li> <li>- зенитный угол ствола скважины;</li> </ul>	<ul style="list-style-type: none"> <li>- увеличение крутящего момента и осевых нагрузок во время бурения;</li> <li>- снижение выхода шлама на виброситах;</li> <li>- повышение давления в нагнетательной линии;</li> <li>- посадка инструмента или плохая передача нагрузки на долото;</li> <li>- увеличение веса при подъеме колонны.</li> </ul>
		Нестабильность ствола скважины: <i>набухание горных пород</i>	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- длина КНБК;</li> <li>- зазор между стенками скважины и наружным диаметром максимально длинной части КНБК;</li> <li>- реологические свойства, технологические параметры бурового раствора;</li> <li>- тип ингибирующего добавка;</li> <li>- тип смазывающего добавка;</li> <li>- содержание смазывающей добавки;</li> </ul>	<ul style="list-style-type: none"> <li>- постепенно усиливающееся трение (сила сопротивления) и увеличение крутящего момента во время бурения и СПО;</li> <li>- повышение давления в нагнетательной линии;</li> <li>- повышение значений реологических параметров бурового раствора;</li> <li>- возможна частичная или полная потеря циркуляции.</li> </ul>
		Нестабильность ствола скважины: <i>осыпи и обвалы стенок скважины; образование сальников; сланцевые глины с АВПД, и т.д.</i>	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- пластовое давление;</li> <li>- дифференциальное давление;</li> <li>- длина КНБК;</li> <li>- зазор между стенками скважины и наружным диаметром максимально длинной части КНБК;</li> <li>- скорость СПО;</li> <li>- скорость потока промывочной жидкости;</li> <li>- реологические свойства, технологические параметры бурового раствора;</li> <li>- тип ингибирующего добавка;</li> <li>- тип смазывающего добавка;</li> <li>- содержание смазывающей добавки;</li> <li>- зенитный угол ствола скважины;</li> <li>- механическая скорость бурения;</li> </ul>	<ul style="list-style-type: none"> <li>- увеличение крутящего момента и осевых нагрузок во время бурения;</li> <li>- резкое увеличение силы трения (сопротивления) при движении инструмента вверх и вниз;</li> <li>- повышение давления в нагнетательной линии;</li> <li>- появление затяжек при наращивание инструмента;</li> <li>- увеличение количество шлама на вибросите;</li> <li>- скачки значений крутящего момента;</li> <li>- частичное поглощение бурового раствора;</li> <li>- первоначальное ускорение механической скорости бурения, за которым следует замедление;</li> <li>- увеличение выхода фоновый газа (содержания концентрации газа в буровом растворе).</li> </ul>
	<b>Прихват вследствие геометрических изменений ствола скважины</b>	Резкий перегиб ствола скважины: <i>образование желобов</i>	<ul style="list-style-type: none"> <li>- количество СПО;</li> <li>- зенитный угол ствола скважины;</li> <li>- частота вращения бурильной колонны;</li> </ul>	<ul style="list-style-type: none"> <li>- стабильная циркуляция;</li> <li>- резкое увеличение силы трения (сопротивления) при подъеме инструмента, и внезапная затяжка КНБК в зоне желоба;</li> <li>- свободное движение КНБК в интервале ниже желоба.</li> </ul>
		Резкий перегиб ствола скважины: <i>жесткая компоновка низа бурильной колонны (КНБК)</i>	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- длина КНБК;</li> <li>- зазор между стенками скважины и наружным диаметром максимально длинной части КНБК;</li> <li>- зенитный угол ствола скважины;</li> <li>- скорость СПО;</li> </ul>	<ul style="list-style-type: none"> <li>- повышение давления в нагнетательной линии;</li> <li>- увеличение крутящего момента и осевых нагрузок при наращивание и спуске инструмента;</li> <li>- не полная циркуляция в интервале подвижных горных пород;</li> </ul>



Продолжение таблицы 2.1.

1	2	3	4	1
Механический прихват	Прихват вследствие геометрических изменений ствола скважины	Сужение диаметра ствола скважины	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- зенитный угол ствола скважины;</li> <li>- скорость СПО;</li> <li>- механическая скорость бурения;</li> <li>- зазор между стенками скважины и наружным диаметром максимально длинной части КНБК;</li> <li>- наружный диаметр долота;</li> <li>- частота вращения бурильной колонны;</li> <li>- давления нагнетания и расход бурового раствора.</li> </ul>	<ul style="list-style-type: none"> <li>- увеличение крутящего момента и осевых нагрузок при наращивание и спуске инструмента;</li> <li>- внезапная посадка инструмента;</li> <li>- стабильная циркуляция;</li> <li>- падение механической скорости бурения;</li> <li>- повышение давления в нагнетательной линии, в призабойной зоне;</li> <li>- затяжки инструмента у забоя скважины или в интервале отбора керна.</li> </ul>
		Вытекание пластичных горных пород	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- зенитный угол ствола скважины;</li> <li>- реологические свойства, технологические параметры бурового раствора;</li> <li>- пластовое давление;</li> <li>- дифференциальное давление;</li> <li>- длина КНБК;</li> <li>- зазор между стенками скважины и наружным диаметром максимально длинной части КНБК;</li> </ul>	<ul style="list-style-type: none"> <li>- не полная циркуляция в интервале подвижных горных пород;</li> <li>- повышение давления в нагнетательной линии;</li> <li>- постепенно усиливающееся трение (сила сопротивления) и увеличение крутящего момента во время бурения и СПО, в интервале подвижных горных пород.</li> </ul>
		Уступы горных пород и т.д.	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- зенитный угол ствола скважины;</li> <li>- механическая скорость бурения;</li> <li>- ДМК;</li> <li>- скорость СПО;</li> <li>- длина КНБК;</li> <li>- зазор между стенками скважины и наружным диаметром максимально длинной части КНБК;</li> <li>- наружный диаметр долота.</li> </ul>	<ul style="list-style-type: none"> <li>- беспорядочные затяжки и посадки инструмента;</li> <li>- стабильная циркуляция;</li> <li>- цикличное увеличение и уменьшение механической скорости бурения.</li> </ul>
Дифференциальный прихват		<p>Время нахождения бурильной колонны в скважине без движения; перепад между пластовым и гидростатическим давлениями; высокая проницаемость пород в скважине (особенно в открытом стволе); высокое значение толщины фильтрационной (глинистой) корки; высокая величина площади соприкосновения бурильной колонны со стенкой скважины; увеличение силы трения между элементами бурильной колонны и стенками скважины.</p>	<ul style="list-style-type: none"> <li>- тип горных пород;</li> <li>- зенитный угол ствола скважины;</li> <li>- пластовое давление;</li> <li>- дифференциальное давление;</li> <li>- длина КНБК;</li> <li>- зазор между стенками скважины и наружным диаметром максимально длинной части КНБК;</li> <li>- реологические свойства, технологические параметры бурового раствора;</li> <li>- тип ингибирующего добавка;</li> <li>- тип смазывающего добавка;</li> <li>- содержание смазывающей добавки;</li> <li>- время нахождения инструмента в стволе скважины без вращения и расхаживания.</li> </ul>	<ul style="list-style-type: none"> <li>- избыточное увеличение крутящего момента и осевых нагрузок инструмента;</li> <li>- длительное время остановки вращения и расхаживания инструмента;</li> <li>- стабильная циркуляция.</li> </ul>

**ПРИЛОЖЕНИЕ В. Акт о внедрении результатов диссертационного  
исследования от ООО «РУСГЕОСЕРВИС»**

«УТВЕРЖДАЮ»

Генеральный директор  
ООО «РУСГЕОСЕРВИС»  
С. Е. Семеген  
2022 г.



Акт

о практическом использовании результатов диссертационной работы  
Кодирова Шахбоза Шарифовича «Разработка алгоритмов обработки данных  
и нейросетевых моделей прогнозирования прихвата технологического  
бурового инструмента»

Настоящим удостоверяется, что результаты диссертационной работы Кодирова Шахбоза Шарифовича, в частности алгоритмы обработки данных и модели прогнозирования прихвата технологического инструмента по глубине и по времени бурения скважины, являются актуальными для практического применения для нашего предприятия. Они позволяют обнаруживать и предвидеть риски и причины надвигающейся прихватов, и позволяют предпринимать своевременные меры по их предотвращению. Программное обеспечение, созданное в результате выполнения диссертационной работы, принято к использованию для прогнозирования прихватов на стадии проектирования и в процессе бурения скважины, в качестве метода оценки и контроля рисков возникновения прихватов.

Применение результатов диссертационной работы позволяют предвидеть риски и причины возникновения прихватов, предпринимать своевременные меры по их предупреждению и повышать технико-экономические показатели бурения скважины.

Руководитель службы ГТИ  
ООО «РУСГЕОСЕРВИС»



М. С. Явтушенко

**ПРИЛОЖЕНИЕ Г. Акт о внедрении результатов диссертационного  
исследования от ОАО «НАФТУ ГАЗ»**

**УТВЕРЖДАЮ**



Генеральный директор  
ОАО «НАФТУ ГАЗ»

*Б.А. Дематов*  
Дематов Б.А.

03.06 2022 г.

**АКТ**

о внедрении результатов диссертационной работы

Кодирова Шахбоза Шарифовича

«Разработка алгоритмов обработки данных и нейросетевых моделей  
прогнозирования прихвата технологического бурового инструмента»

Настоящий акт составлен в том, что результаты диссертационной работы Кодирова Шахбоза Шарифовича в виде программного обеспечения приняты к использованию для прогнозирования прихватов технологического инструмента на стадии проектирования и в процессе бурения скважины в качестве метода диагностики прихватов.

Эффект от внедрения результатов диссертационной работы заключается в повышении эффективности бурения за счет сокращения числа непредвиденных прихватов и уменьшения непроизводительных затрат времени на ликвидацию прихватов.

Начальник ПТО  
ОАО «Нафту газ»

*Юнусов Ю.Ш.*

Юнусов Ю.Ш.



## ПРИЛОЖЕНИЕ Д. Патент на изобретение №2735794

## РОССИЙСКАЯ ФЕДЕРАЦИЯ



ПАТЕНТ

НА ИЗОБРЕТЕНИЕ

№ 2735794

## Способ прогнозирования прихватов буровых труб

Патентообладатель: *Федеральное государственное автономное образовательное учреждение высшего образования "Южно-Уральский государственный университет (национальный исследовательский университет)" ФГАОУ ВО "ЮУрГУ (НИУ)" (RU)*

Авторы: *Шестаков Александр Леонидович (RU),  
Кодиров Шахбоз Шарифович (TJ)*

Заявка № 2020121477

Приоритет изобретения 23 июня 2020 г.

Дата государственной регистрации в

Государственном реестре изобретений

Российской Федерации 09 ноября 2020 г.

Срок действия исключительного права  
на изобретение истекает 23 июня 2040 г.

Руководитель Федеральной службы  
по интеллектуальной собственности

*Г.П. Ивлиев* Г.П. Ивлиев



## ПРИЛОЖЕНИЕ Е. Патент на изобретение №2753289

РОССИЙСКАЯ ФЕДЕРАЦИЯ

**ПАТЕНТ**

НА ИЗОБРЕТЕНИЕ

№ 2753289

**Способ прогнозирования прихватов бурильных труб в процессе бурения скважины в режиме реального времени**

Патентообладатель: *Федеральное государственное автономное образовательное учреждение высшего образования «Южно-Уральский государственный университет (национальный исследовательский университет)» (RU)*

Авторы: *Шестаков Александр Леонидович (RU), Кодиров Шахбоз Шарифович (TJ)*

Заявка № 2020134345

Приоритет изобретения 20 октября 2020 г.

Дата государственной регистрации в Государственном реестре изобретений Российской Федерации 12 августа 2021 г.

Срок действия исключительного права на изобретение истекает 20 октября 2040 г.

Руководитель Федеральной службы по интеллектуальной собственности

Г.П. Ивлиев

