

## Автоматизированная система предотвращения аварий при строительстве скважин

Automated system for preventing accidents during well construction

A.N. Dmitrievsky<sup>1,2</sup>, N.A. Eremin<sup>1,2</sup>, A.D. Chernikov<sup>1</sup>, A.G. Sboev<sup>3</sup>, O.K. Chashchina-Semenova<sup>1</sup>, L.K. Fitzner<sup>1</sup>, M.Ya. Gelfgat<sup>2</sup>, A.A. Nazaretova<sup>2</sup>

<sup>1</sup>Oil and Gas Research Institute of RAS, RF, Moscow

<sup>2</sup>Gubkin University, RF, Moscow

<sup>3</sup>National Research Center Kurchatov Institute, RF, Moscow

E-mail: a.dmitrievsky@ipng.ru, ermn@mail.ru, cha60@mail.ru, sag11@mail.ru, sineton@yahoo.com, folnons@yahoo.com, mikhailgelfgat@gmail.com, anazaretova@bk.ru

**Keywords:** machine learning, neural networks, anomaly detection, forecasting of complications, well drilling, geological and technological information, Big GeoData, accident prevention, artificial intelligence, automated system, well construction, neural network modeling

Digital modernization of oil and gas production is a powerful tool for increasing the efficiency of field development and an innovative driver for the development of the oil and gas industry. Leading oil and gas companies in Russia are transitioning to digital technologies for drilling and production based on the use of machine learning methods and neural network models. An oil and gas well is the main technological object and structure that determines the efficiency of hydrocarbon production at all stages of the field life cycle. The objects of research were complications and emergencies during the construction of oil and gas wells. The purpose of the work is to increase the efficiency of the construction process of oil and gas wells based on the creation of a high-performance automated system for preventing complications and emergencies. This article briefly describes the created automated system for preventing emergency situations during well construction using artificial intelligence technologies. The structure of the automated system and the composition of the main software components are given. The efficiency of the automated system is based on providing the calculation model with a mechanism for a continuous system of transmission, collection, distribution, storage and validation of large volumes of geological and geophysical data (Big GeoData) with elements of blockchain technology. The main advantage of using neural network modeling to solve problems of identifying and predicting complications during the construction of oil and gas wells is to reveal hidden patterns between geological and geophysical, technical and technological parameters. The system has the ability to scale and integrate into any existing oil and gas control and monitoring systems.

В настоящее время значительное развитие получили современные методы анализа данных (Data Driven methods) и математические модели, в том числе на основе технологий машинного обучения и нейронных сетей. Благодаря этим технологиям разработаны алгоритмы, позволяющие эффективно решать сложные задачи в нефтегазовой отрасли [1–4]. Объектами исследования являлись осложнения и аварийные ситуации в процессе строительства нефтяных и газовых скважин. Цель работы заключалась в повышении эффективности этого процесса на основе создания высокопроизводительной автоматизированной системы предотвращения осложнений и аварийных ситуаций.

Сбор и накопление больших геоданных со станций геолого-технологических измерений (ГТИ) в процессе бурения скважин позволили создать средства автоматизированного прогнозирования осложнений и аварийных ситуаций путем построения интеллектуальных моделей. В частности, в исследовании [5] была рассмотрена задача автоматического выявления поломок механизмов и определения их типов на основе исторических данных, кото-

А.Н. Дмитриевский<sup>1,2</sup>, академик РАН, д.г.-м.н.,  
Н.А. Еремин<sup>1,2</sup>, д.т.н.,  
А.Д. Черников<sup>1</sup>, к.т.н.,  
А.Г. Сбоев<sup>3</sup>, к.т.н.,  
О.К. Чашина-Семенова<sup>1</sup>, к.ф.-м.н.,  
Л.К. Фишнер<sup>1</sup>, к.ф.-м.н.,  
М.Я. Гельфгат<sup>2</sup>, к.т.н.,  
А.А. Назаретова<sup>2</sup>, к.ю.н.

<sup>1</sup>Институт проблем нефти и газа РАН  
<sup>2</sup>РГУ нефти и газа (НИУ) имени И.М. Губкина  
<sup>3</sup>НИЦ «Курчатовский институт»

Адреса для связи: a.dmitrievsky@ipng.ru, ermn@mail.ru, cha60@mail.ru, sag11@mail.ru, sineton@yahoo.com, folnons@yahoo.com, mikhailgelfgat@gmail.com, anazaretova@bk.ru

**Ключевые слова:** машинное обучение, нейронные сети, выявление аномалий, прогнозирование осложнений, бурение скважин, геолого-технологическая информация, большие геоданные, предотвращение аварий, искусственный интеллект, автоматизированная система, строительство скважин, нейросетевое моделирование

DOI: 10.24887/0028-2448-2021-1-72-76

Статья подготовлена в рамках работ по теме государственного задания «Фундаментальный базис инновационных технологий нефтяной и газовой промышленности» No AAAA-A19-119013190038-2 в РОСРИДе

рая была сведена к классической задаче машинного обучения ((ML – machine learning) – обнаружению аномалий. В работе [5] представлен обширный обзор методов решения этой задачи, а также приведены результаты их апробации на фактических данных. Лучший результат показал подход «обучение без учителя», а именно модель «изолирующего леса» (Isolation Forest) [6].

В работе [7] задача выявления осложнений и определения их типов в процессе бурения решалась путем построения модели машинного обучения для нахождения аномалий данных. В этом исследовании применялся подход «обучение с учителем». Данные со станций ГТИ, полученные в режиме реального времени, сравнивались с аналогичными, ранее собранными в базе данных, которые отражали различные типы осложнений. Результаты поиска ранжировались и выбиралось наиболее подходящее осложнение. Для сравнения, ранжирования и определения осложнения была обучена классификационная модель градиентного бустинга [8], которая позволила добиться точности определения осложнений, равной 90,8 % по метрике ROC AUC, т.е. вычислить площадь под кривой

эксплуатационных характеристик. Метрика ROC AUC является одной из широко используемых в отрасли, где AUC (Area Under The Curve) – площадь под кривой, представленной кривой ROC (Receiver Operating Characteristic) эксплуатационных характеристик приемника. На практике в зависимости от значения AUC эффективность работы модели классифицируется следующим образом:  $0,8 \leq AUC \leq 1,0$  – работает очень хорошо;  $0,6 \leq AUC < 0,8$  – работает хорошо;  $0,5 < AUC < 0,6$  – работает удовлетворительно;  $AUC \leq 0,5$  – не работает. В статье [9] рассмотрен метод определения прихвата колонны бурильных труб на основе нейронной сети. Авторами построена многослойная полносвязная нейронная сеть MLP (Multilayer Perceptron), которая определяла возникновение прихвата и его тип с точностью 93 % по базовой метрике Accuracy (измеряет число верно классифицированных объектов относительно общего числа всех объектов).

Общее число параметров, которые регистрируются станциями геолого-технологических измерений (ГТИ) в процессе бурения, варьируется от 60 до 180. Из множества параметров ГТИ формируется подмножество входных ключевых параметров для моделей искусственных нейронных сетей (ANNs), которые используются для предотвращения осложнений и аварий при бурении. Подмножество входных ключевых параметров для ИНН включает в себя от 20 до 40 характеристик, в том числе синтетические. Высокочастотные данные при бурении скважин записываются в масштабе времени со средней частотой  $3-10 \text{ с}^{-1}$ , а также по глубине в масштабе 0,1 м. Данные представляют собой XML файлы, сформированные в стандарте WITSML (Wellsite Information Transfer Standard Markup Language – стандарт для передачи данных со скважины в формате XML). Анализ показал, что основной массив данных представляет собой временные последовательности (timeseries), что предполагает использование топологии ИНС на базе рекуррентных слоев. В рекуррентных нейронных сетях нейроны обмениваются информацией между собой, таким образом, вместе с новыми данными нейрон получает информацию о предыдущем состоянии сети [10–12]. Рекуррентную нейронную сеть можно описать следующими соотношениями:

$$A_t = f(Vx_t + UH_{t-1} + b_n), \quad (1)$$

$$y_t = g(WH_t + b_y), \quad (2)$$

где  $x_t$  – входной вектор номер  $t$ ;  $h_t$  – состояние скрытого слоя для входа  $x_t$ ;  $y_t$  – выход сети для входа  $x_t$ ;  $U$  – весовая матрица распределительного слоя;  $W$  – весовая матрица обратных связей скрытого слоя;  $b_n$  – вектор сдвигов скрытого слоя;  $V$  – весовая матрица выходного слоя;  $b_y$  – вектор сдвигов выходного слоя;  $f$  – функция активации скрытого слоя;  $g$  – функция активации выходного слоя.

Задачи прогнозирования различных параметров бурения в режиме реального времени являются еще более сложными [13, 14] и на данном этапе развития методов машинного обучения проработаны слабо. Самые успешные методы их решения основаны на глубоких нейронных сетях с рекуррентными и конволюционными слоями [15, 16].

Рассмотренные выше модели прогнозирования позволяют только оценить риски будущего бурения скважин и заранее подготовиться к возможным осложнениям в процессе бурения, однако они не позволяют прогнози-

ровать осложнения так, чтобы буровая бригада смогла в режиме реального времени выполнить своевременные действия по их полному предотвращению или минимизировать негативные последствия. Для таких прогнозов необходимо использовать данные станций ГТИ, получаемые в режиме реального времени.

В статье рассмотрены различные подходы к прогнозированию наступления предаварийных ситуаций трех типов в процессе бурения с использованием размеченных и неразмеченных наборов данных:

- 1) газонефтеводопроявление (ГНВП);
- 2) прихват бурильной колонны;
- 3) поглощение бурового раствора.

В процессе разработки методов и проведения запланированных экспериментов использовалась информация, предоставленная партнерами из РГУ нефти и газа (НИУ) имени И.М. Губкина в виде симуляционных данных, полученных с бурового тренажера, а также данные со станций ГТИ при бурении скважин на реальных месторождениях. Оба набора данных состоят из показаний, снимаемых датчиками в процессе бурения скважины (или его симуляции), установленными на оборудовании. Число отслеживаемых параметров, полнота и частота их записи в указанных наборах данных различаются, что дополнительно осложняет проведение анализа.

**Симуляционные данные.** Симуляционный набор данных был получен по результатам проведения экспериментов по моделированию процесса бурения на тренажере DrillSim-5000. Из 79 записей симуляций 33 относятся к бурению с ГНВП, 27 – со шламонакоплением (прихватом), 9 – с поглощением бурового раствора и 10 – к безаварийному бурению.

Данные записей симуляций с тренажера представлены в виде таблиц с 16 параметрами, включающими вес на крюке, скорость проходки, частоту вращения долота и др. Для каждой симуляционной записи была предоставлена метка времени, которая означала начало развития каждого моделируемого осложнения. Метка времени проставлялась вручную экспертами в области бурения.

**Данные с реального месторождения.** В качестве данных с разбуриваемых месторождений были представлены реальные временные записи отслеживаемых параметров в процессе бурения 25 скважин, из них для 23 скважин указаны записи штатного бурения; для одной – записи с осложнением «Прихват», для одной – с осложнением «Поглощение». Некоторые отслеживаемые параметры приведены в таблице. Разметка данных выполнена специалистами по бурению и включала указание времени начала осложнения для каждого из двух типов осложнений (прихват и поглощение).

Для того, чтобы данные можно было использовать в методах машинного обучения и провести качественный анализ, необходимо их предварительно подготовить. Для анализа были отобраны отрезки непрерывного бурения (наблюдения с ненулевой скоростью проходки), на которых исключались все значения параметров, соответствующие моментам времени после начала осложнения заданного типа, так как такие наблюдения не представляют интереса для прогнозирования его наступления. В связи с тем, что частота снятия параметров в симуляционных данных от эксперимента к эксперименту варьировалась, для их выравнивания использова-

Параметры	Значение		Число уникальных значений
	среднее	максимальное	
Вес на крюке, 10 кН	3,84	46,82	4513
Давление, кПа	1840,83	23781,44	87313
Талевый блок, м	10,83	25,27	2520
Глубина забоя, м	625,52	849,01	20745
Нагрузка на долото, 10 кН	1,17	19,98	1865

лась линейная интерполяция по двум соседним точкам. Итоговый шаг по времени между точками – 2 с. Из всех параметров были выбраны основные, которые представляют наибольший интерес для определения рассматриваемых осложнений, а также присутствуют в обоих наборах данных:

- 1) нагрузка на крюк, фунты;
- 2) механическая скорость проходки, фут/ч;
- 3) частота вращения ротора, мин<sup>-1</sup>;
- 4) разница между значениями потока бурового раствора на выходе и входе, баррель;
- 5) давление насоса, фунт/дюйм<sup>2</sup>.

Для расширения пространства признаков и их нормализации использовались дополнительные производные параметры, получаемые из показаний датчиков, отобранные после предварительной подготовки данных, в том числе разница между текущим и предыдущим значениями, расчет скользящего тренда и разложение значений параметров на угол наклона тренда и отклонение от него, расчет процентилей значений параметров и их нормирование в пределах процентилей. Данные были разделены на тренировочные и тестовые наборы. В случае с симуляционными данными для каждого рассматриваемого осложнения выделен свой тестовый набор скважин, включающий 20 % всех скважинных записей, содержащих рассматриваемое осложнение, а также 20 % случайно выбранных безаварийных скважин.

Для решения задачи прогнозирования наступления различных предаварийных ситуаций (осложнений), в частности, прихватов, поглощений и ГНВП, были реализованы подходы на основе:

- 1) выделения аномалий с построением:
  - а) одноклассовой модели машинного обучения;
  - б) регрессионной нейросетевой модели;
- 2) построения регрессионной функции индикатора, отражающей приближение к вероятному осложнению.

Подходы 1а и 2 были апробированы на симуляционных данных, полученных с бурового тренажера, так как в них содержался набор размеченных примеров по различным осложнениям. Подход 1б применялся к реальным данным (два тестовых примера по осложнениям «Прихват» и «Поглощение»), размеченные тренировочные примеры отсутствовали.

**Модель выделения аномалий.** Данный подход основан на выделении аномалий в снимаемых показаниях наблюдаемых параметров бурения. Чем ближе к осложнению рассматриваются значения наблюдаемых параметров бурения, тем больше они отличаются от тех, которые характерны для безаварийного штатного бурения в таких же условиях. Такой подход позволяет использовать большой объем неразмеченных данных, выделяя аномальные отклонения параметров бурения, а также необычную совокупность их значений. Для построения модели применялся метод изолирующего леса (Isolation Forest) с параметром  $n\_estimators$ , равным 500. Метод взят из библиотеки с открытым исходным кодом sklearn и заключается в построении случайного бинарного решающего дерева, которое может распознавать аномалии различных видов: изолированные точки с низкой локальной плотностью и кластеры аномалий малых размеров.

**Модель прогнозирования функции-индикатора.** Данная модель основана на введении функции индикатора, имеющей нулевое значение на временном интервале, достаточно удаленном от предаварийной ситуации, и возрастающей по мере приближения к предаварийной ситуации (рис. 1). При обучении модели функция-индикатор задавалась в виде сигмоидальной функции, принимающей значение 0,5 за 7 мин до аварии и близкое к 1 мин в точке начала аварии. Сигнал о приближающемся осложнении поступает при превышении заданного порога, рассчитанного по тренировочной выборке примеров. Модель использует метод на основе случайного леса (Random Forest) со 100 деревьями, и начинает превышать порог в среднем за 4–5 мин до возникновения осложнения.

**Нейросетевая модель для реальных данных.** Для проведения экспериментов с данными реального бурения невозможно использовать подходы «обучение с учителем». Для таких подходов необходим достаточный набор размеченных данных. В связи с этим было принято решение использовать подход, схожий с подходом «выделение аномалий», и решать аналогичную задачу с оценкой разработанного метода на имеющихся размеченных примерах осложнений «Прихват» и «Поглощение». Для обработки реальных данных и подачи их в нейросетевую модель применяется подход скользяще-




Рис. 1. Регрессионное прогнозирование функции индикатора

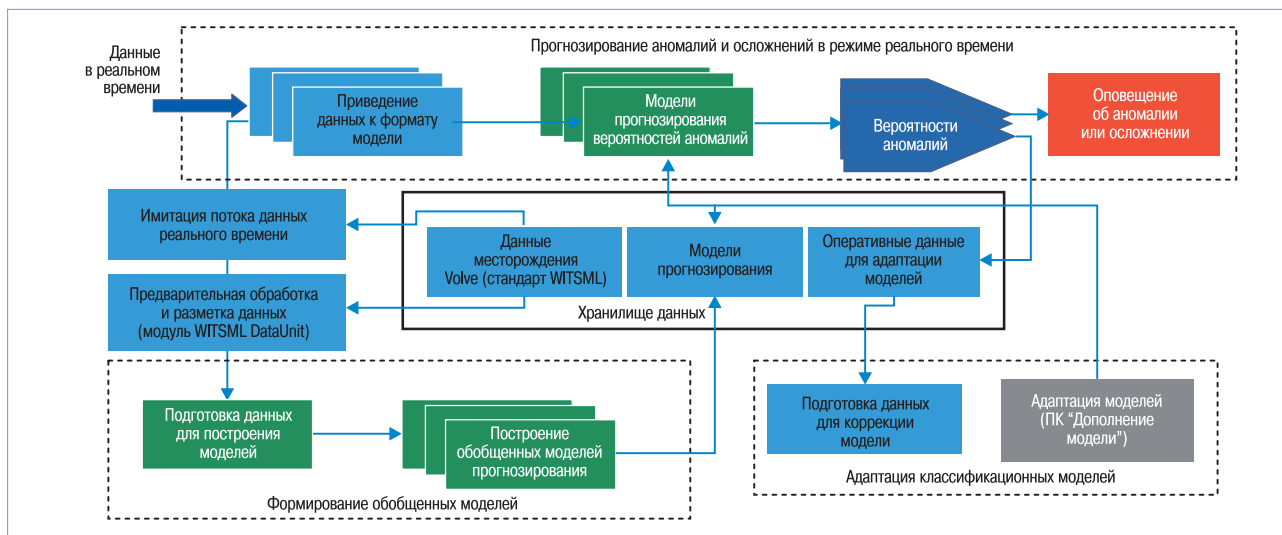


Рис. 2. Функциональная схема организации производственных процессов, реализуемая программным компонентом «Оркестровка»

го окна с перекрытием. Модель использует пять отобранных параметров, для которых формируется окно с 1024 последовательными значениями. Полученная матрица подается на вход модели, которая обучается прогнозировать пять параметров на следующем шаге.

Разработанная автоматизированная система предотвращения аварийных ситуаций предназначена для оказания помощи персоналу буровых бригад в выявлении возможных осложнений на краткосрочную перспективу.

На рис. 2 синим цветом обозначены блоки, входящие в состав компонента «Оркестровка», зеленым цветом – блоки, входящие в состав программного компонента «Нейросетевые расчеты», серым цветом – блоки, входящие в состав программного компонента «Адаптация обобщенных нейросетевых моделей прогнозирования осложнений и аварийных ситуаций к геофизическим параметрам при бурении конкретной скважины», и оранжевым цветом – блоки, входящие в состав программного компонента «Обратная связь». Прогнозирование осуществляется на основе  $N$  кадров предыдущей информации (по умолчанию  $N = 1000$ ) и прогноз по значениям параметров выдается на  $M$  (по умолчанию  $M = 150$ ) кадров вперед. Полученные в результате построения прогноза кадры информации используются для оценки вероятности осложнения с помощью моделей прогнозирования, и результаты оценки вероятности осложнений передаются в ПК «Обратная связь». Дополнительно эти результаты сохраняются (накапливаются) в хранилище данных и затем могут быть использованы в качестве входных данных для адаптации моделей прогнозирования. В блок прогнозирования вероятностей аномалий включены модули, входящие в состав ПК «Нейросетевые расчеты» и выполняющие расчет вероятности возникновения аномалии на время  $\Delta T$  с использованием актуальных моделей (обобщенных или адаптированных). Актуальные ML или ИНС модели считываются из хранилища данных при загрузке каждого модуля. Модули дополнены блоками, осуществляющими прием и отсылку сообщений с использованием библиотеки ZeroMQ. Входными данными, используемыми для формирования обобщенных моделей, являются наборы реально-временных данных о процессе бурения, содержащие записи о произошедших осложнениях «Прихват», «Поглощение» и «ГНВП» с указанием момента времени начала осложнения.

Созданная автоматизированная система предотвращения аварийных ситуаций при строительстве скважин с использованием методов машинного обучения характеризуется способностью к «запоминанию» обнаруженных закономерностей на долгие промежутки времени и возможностью непрерывного дообучения в процессе функционирования. Автоматизированная система предотвращения аварий при строительстве скважин включает в себя пять программных компонентов. Программный компонент «Нефтегазовый блокчейн» предназначен для использования в автоматизированной системе предупреждения осложнений и аварийных ситуаций при строительстве нефтяных и газовых скважин в целях обеспечения целостности и безопасности передачи, распределения и сохранения технических и геолого-технологических данных с применением технологий индустриального блокчейна. Программный компонент «Нейросетевые расчеты – построение моделей прогноза осложнений и аварийных ситуаций при бурении и строительстве скважин» (ПКНР) предназначен для принятия превентивных мер по предотвращению осложнений при бурении. Ситуация приближения к аномалии определяется совокупностью параметров и не может быть гарантированно выявлена в результате визуальных наблюдений. Для решения задачи прогнозирования осложнений используется бинарная классификация. Используемые алгоритмы: нейросеть (перцептрон) TensorFlow (Keras). Обобщенные модели прогнозирования осложнений и аварийных ситуаций типа «прихват», «поглощение» и «газонефтеводопроявление» в процессе бурения скважины формируются с использованием априорных данных со станций геолого-технологических измерений с других пробуренных скважин, близких по геологическим условиям. Программный компонент «Адаптация обобщенных нейросетевых моделей прогнозирования осложнений и аварийных ситуаций к геофизическим параметрам при бурении конкретной скважины» предназначен для повышения точности прогноза возможных отклонений за счет коррекции (адаптации) исходных (обобщенных) моделей прогнозирования для конкретных скважин. Базовая (обобщенная) модель обобщает всю имеющуюся информацию по каждому типу осложнений по конкретному месторождению или по сумме месторождений с учетом их геологических данных, что расширяет



ее общность и возможность адаптации к условиям конкретной скважины. Программный компонент «Индикация прогноза осложнений и аварийных ситуаций при бурении и строительстве скважин» (ПК «Индикация») предназначен для формирования предупреждающих сигналов о возможных осложнениях и выдачи рекомендаций для бурильщика по предотвращению последствий прогнозируемых осложнений. Разработанный программный компонент «Оркестровка» организует взаимодействие программных компонентов и модулей, входящих в автоматизированную систему предотвращения осложнений и аварийных ситуаций в процессе строительства нефтяных и газовых скважин. Основным результатом работы данного программного компонента является предупреждение об аварии или осложнении в процессе строительства скважин. Созданный программный компонент «Обратная связь» выдает рекомендации инженеру-бурильщику в случае возникновения аварии или осложнения. При вероятности прогноза осложнения более 0,5 формируется рекомендация, соответствующая данной аварии или осложнению. Для формирования рекомендаций разработан алгоритм выбора рекомендаций из базы знаний, содержащейся в основном хранилище данных.

Масштабное внедрение автоматизированной системы предотвращения аварийных ситуаций при строительстве скважин позволит сократить сроки бурения более чем на 10–25 % и стоимость скважин на 5–25 %.

## Список литературы

1. Качественный анализ геоданных временного ряда для предупреждения осложнений и аварийных ситуаций при бурении нефтяных и газовых скважин / А.Н. Дмитриевский, Н.А. Ерёмин, Е.А. Сафарова [и др.] // Научные труды НИПИ Нефтегаз ГНКР. – № 3 (2020). – С. 031–037. – DOI: 10.5510/ogp20200300442
2. Казначеев П.Ф., Самойлова Р.В., Курчиски Н.В. Применение методов искусственного интеллекта для повышения эффективности в нефтегазовой и других сырьевых отраслях // Экономическая политика. – 2016. – Т. 11. – № 5. – С. 188–197.
3. Об увеличении продуктивного времени бурения нефтегазовых скважин с использованием методов машинного обучения / А.Н. Дмитриевский, А.Г. Сбоев, Н.А. Ерёмин [и др.] // Георесурсы. – 2020. – 22(4). – С. 79–85. – DOI: <https://doi.org/10.18599/grs.2020.4.79-85>.
4. Применение методов искусственного интеллекта для выявления и прогнозирования осложнений при строительстве нефтяных и газовых скважин: проблемы и основные направления решения / А.Д. Черников, Н.А. Ерёмин, В.Е. Столярков [и др.] // Георесурсы. – 2020. – 22 (3). – С. 87–96. – DOI: <https://doi.org/10.18599/grs.2020.3.87-96>
5. Дьяконов А.Г., Головина А.М. Выявление аномалий в работе механизмов методами машинного обучения // Аналитика и управление данными в областях с интенсивным использованием данных / Тр. XIX Международной конференции DAMDID / RCDL 2017. – 10–13 октября 2017 г., Москва. – М.: ФИ ЦИУ РАН. – 2017. – С. 469–476.
6. Liu F.T., Tony T.K.M., Zhou Z.H. Isolation forest // Proceedings of the 2008 Eighth IEEE Int. Conf. on Data Mining. – 2008. – P. 413–422.
7. Application of machine learning to accidents detection at directional drilling / E. Gurina [et al.] // Journal of Petroleum Science and Engineering. – 2020. – Т. 184. – P. 106519. – DOI: [10.1016/j.petrol.2019.106519](https://doi.org/10.1016/j.petrol.2019.106519).
8. Chen T., Guestrin C. Xgboost: A scalable tree boosting system // Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. – ACM. – 2016. – P. 785–794.
9. Кодиров Ш.Ш., Шестаков А.Л. Разработка искусственной нейронной сети для прогнозирования прихватов колонн бурильных труб // Вестник Южно-Уральского государственного университета. Серия. Компьютерные технологии, управление, радиоэлектроника. – 2019. – Т. 19. – № 3. – С. 20–32.
10. Автоматизированная система выявления и прогнозирования осложнений в процессе строительства нефтяных и газовых скважин // А.Н. Дмитриевский, Н.А. Ерёмин, О.К. Чашчина-Семенова, Л.К. Фицнер, А.Д. Черников Патент на полезную модель RU. Заявка № 2020129673/03 (053361) от 08.09.2020.
11. Дмитриевский А.Н., Ерёмин Н.А., Чашчина-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.
12. Система для прогнозирования осложнений в бурении на основе искусственного интеллекта / С.О. Бороздин, А.Н. Дмитриевский, Н.А. Ерёмин [и др.] / SPE-202546-MS-2020.
13. Анализ качества данных станции геолого-технологических исследований при распознавании поглощений и газонефтеводопроявлений для повышения точности прогнозирования нейросетевых алгоритмов / А.И. Архипов, А.Н. Дмитриевский, Н.А. Ерёмин [и др.] // Нефтяное хозяйство. – 2020. – № 8. – С. 63–67. – DOI: [10.24887/0028-2448-2020-8-63-67](https://doi.org/10.24887/0028-2448-2020-8-63-67)
14. Noshi C.I., Schubert J.J. The Role of Machine Learning in Drilling Operations. A Review // SPE-191823-18ERM-MS. – 2018. – DOI: [10.2118/191823-18ERM-MS](https://doi.org/10.2118/191823-18ERM-MS).
15. Real-Time Well Log Prediction From Drilling Data Using Deep Learning / R. Kanfar [et al.] // arXiv preprint arXiv:2001.10156. – 2020.
16. Deep learning for well data history analysis / Y. Li [et al.] // SPE-196011-MS. – 2019.

## References

1. Dmitrievskiy A.N., Eremin N.A., Safarova E.A. et al., *Qualitative analysis of time series geodata to prevent complications and emergencies during drilling of oil and gas wells* (In Russ.), Nauchnye trudy NIPI Nefttegaz GNKAR = SOCAR Proceedings, 2020, no. 3, pp. 31–37, doi: [10.5510/ogp20200300442](https://doi.org/10.5510/ogp20200300442)
2. Kaznacheev P.F., Samoylova R.V., Kurchiski N.V., *Application of artificial intelligence methods to improve efficiency in the oil and gas and other raw materials industries* (In Russ.), Ekonomicheskaya politika = Economic policy, 2016, V. 11, no. 5, pp. 188–197.
3. Dmitrievskiy A.N., Sboev A.G., Eremin N.A. et al., *On increasing the productive time of drilling oil and gas wells using machine learning methods* (In Russ.), Georesursy = Georesources, 2020, V. 22, no. 4, pp. 79–85, DOI: <https://doi.org/10.18599/grs.2020.4.79-85>.
4. Chernikov A.D., Eremin N.A., Stolyarov V.E. et al., *Application of artificial intelligence methods for identifying and predicting complications in the construction of oil and gas wells: Problems and solutions* (In Russ.), Georesursy = Georesources, 2020, V. 22, no. 3, pp. 87–96, DOI: <https://doi.org/10.18599/grs.2020.3.87-96>
5. D'yakonov A.G., Golovina A.M., *Vyyavlenie anomalii v rabote mekhanizmov metodami mashinnogo obucheniya* (Anomaly detection in mechanisms using machine learning), Proceedings of XIX International conference "Analitika i upravlenie dannymi v oblastiakh s intensivnym ispol'zovaniem dannykh" (Data Analytics and Management in Data Intensive Domains (DAMDID)), Moscow, 10–13th of October 2017, pp. 469–476.
6. Liu F.T., Tony T.K.M., Zhou Z.H., *Isolation forest*, Proceedings of the 2008 Eighth IEEE Int. Conf. on Data Mining, 2008, pp. 413–422.
7. Gurina E. et al., *Application of machine learning to accidents detection at directional drilling*, Journal of Petroleum Science and Engineering, 2020, V. 184, DOI: [10.1016/j.petrol.2019.106519](https://doi.org/10.1016/j.petrol.2019.106519).
8. Chen T., Guestrin C., *Xgboost: A scalable tree boosting system*, Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining, ACM, 2016, pp. 785–794.
9. Kodirov Sh.Sh., Shestakov A.L., *Development of artificial neural network for predicting drill pipe sticking* (In Russ.), Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta. Seriya. Komp'yuternye tekhnologii, upravlenie, radioelektronika, 2019, V. 19, no. 3, pp. 20–32.
10. Utility model patent application no. 2020129673/03 (053361), *Avtomatizirovannaya sistema vyyavleniya i prognozirovaniya oslozhneniy v protsesse stroitel'stva neftyanykh i gazovykh skvazhin* (Automated system for identifying and predicting complications during the construction of oil and gas wells), Inventors: Dmitrievskiy A.N., Eremin N.A., Chashchina-Semenova O.K., Fitsner L.K., Chernikov A.D.
11. Utility model patent application no. 2020129671/03 (053358), *Avtomatizirovannaya sistema vyyavleniya i prognozirovaniya oslozhneniy v protsesse stroitel'stva neftyanykh i gazovykh skvazhin* (Automated system for identifying and predicting complications during the construction of oil and gas wells), Inventors: Dmitrievskiy A.N., Eremin N.A., Chashchina-Semenova O.K., Fitsner L.K., Chernikov A.D.
12. Borozdin S.O., Dmitrievskiy A.N., Eremin N.A. et al., *Drilling problems forecast system based on neural network* (In Russ.), SPE-202546-RU, 2020, doi: [10.2118/202546-RU](https://doi.org/10.2118/202546-RU)
13. Arkhipov A.I., Dmitrievskiy A.N., Eremin N.A. et al., *Data quality analysis of the station of geological and technological researches in recognizing losses and kicks to improve the prediction accuracy of neural network algorithms* (In Russ.), Neftyanoe khozyaystvo = Oil Industry, 2020, no. 8, pp. 63–67, DOI: [10.24887/0028-2448-2020-8-63-67](https://doi.org/10.24887/0028-2448-2020-8-63-67)
14. Noshi C.I., Schubert J.J., *The role of machine learning in drilling operations. A review*, SPE-191823-18ERM-MS, 2018, DOI: [10.2118/191823-18ERM-MS](https://doi.org/10.2118/191823-18ERM-MS).
15. Kanfar R. et al., *Real-time well log prediction from drilling data using deep learning*, arXiv preprint arXiv:2001.10156, 2020.
16. Yuanjun Li et al., *Deep learning for well data history analysis*, SPE-196011-MS, 2019, <https://doi.org/10.2118/196011-MS>