

Прогнозирование отказов глубинного насосного оборудования, предиктивная диагностика и аналитика технического состояния ГНО

ENG

А.А. Облецов, ObletsovAA@neftisa.ru
/АО «НК «Нефтиса», г. Москва/

М.Ю. Данько, Danko@togi.ru
Е.А. Симаков, М.А. Меркель, Р.Б. Аубакиров
/ООО «ТИНГ», г. Тюмень/

Современные возможности получения и передачи информации о состоянии глубинного насосного оборудования на месторождениях углеводородов позволяют реализовывать новые методики в области управления, основанные на алгоритмах искусственного интеллекта. Применение больших данных дает возможность прогнозировать отказы насосного оборудования и принимать превентивные меры до возникновения аварийной ситуации. Это приводит к минимизации времени простоя скважины и повышению рентабельности разработки месторождения. В целом по России ежегодно происходит более 50 000 отказов глубинного насосного оборудования, что влечет за собой значительные финансовые потери нефтедобывающих компаний и увеличение времени простоя скважин. В статье приводятся результаты апробации алгоритмов предиктивной аналитики отказов насосного оборудования, реализованных в программном обеспечении «АТЛАС – Диспетчер скважин».

КЛЮЧЕВЫЕ СЛОВА: механизированная добыча нефти, глубинное насосное оборудование (ГНО), штанговый глубинный насос (ШГН), электроприводный центробежный насос (ЭЦН), отказы глубинного насосного оборудования, контроль и управление ГНО, выявление предаварийного режима работы скважины, алгоритмы машинного обучения, расчетное ядро для предсказания отказов ШГН, осложнения при работе ШГН, предиктивная аналитика отказов ЭЦН, ПО «АТЛАС – Диспетчер скважин», предиктивная аналитика состояния ГНО, нейросетевые технологии управления добычей, оптимизация системы заводнения с помощью алгоритмов искусственного интеллекта, оптимальные режимы эксплуатации нагнетательных скважин, выявление осложнений при эксплуатации ГНО, реализация проекта интеллектуального месторождения

Prediction of Down-hole Pumping Equipment Failures, Predictive Diagnostics and Analysis of this Equipment Technical Status

A.A. Obletsov /OC Neftisa JSC, Moscow/
M.Yu. Danko, E.A. Simakov, M.A. Merkel,
R.B. Aubakirov /TING LLC, Tyumen/

Modern capabilities for obtaining and transmitting information about the state of deep pumping equipment at oil fields allow the implementation of new management techniques based on artificial intelligence. One of the possibilities of implementing Big Data is forecasting failures of pumping equipment, which makes it possible to take preventive measures even before an emergency situation occurs. This leads to minimizing the downtime of the well and increasing the profitability of development. In general, more than 50,000 failures of deep pumping equipment occur annually in Russia. This paper presents the results of testing algorithms for predictive failure analysis of pumping equipment implemented in the software «ATLAS – Well Manager».

KEY WORDS: artificial oil lift, down-hole pumping equipment (DPE), down-hole sucker rod pump (DSRP), electric centrifugal pump (ECP), failures of down-hole pumping equipment, monitoring and control over DPE, identification of pre-emergency well operation mode, machine learning algorithms, computerized base to predict DSRP failures, complications in course of DSRP operation, predictive analytics for ESP failures, "ATLAS – Well Manager" software, predictive analytics of DPE status, neural processes in production control, optimization of flooding system with the use of artificial intelligence algorithms, optimal modes of injection well operation, identification of complications in course of DPE operation, implementation of smart field project

Большая часть углеводородного сырья в России добывается механическим способом, доля скважин механизированного фонда превышает 95 % [1]. При этом основным способом механизированной добычи нефти является эксплуатация двух основных типов глубинного насосного оборудования (ГНО): штангового глубинного насоса (ШГН) и электроприводного центробежного насоса (ЭЦН). При длительной эксплуатации механизированного фонда скважин происходит постепенный износ узлов и агрегатов установок, что впоследствии приводит к отказу оборудования и невозможности его дальнейшей эксплуатации без проведения ремонтных работ. В частности, отказы, связанные с осложненным режимом эксплуатации ГНО, могут привести не только к кратковременному простоем скважины, но и к последующим осложнениям в ходе спускоподъемных операций при извлечении ГНО, что, в свою очередь, чревато полной потерей работоспособности скважины.

В целом по России ежегодно происходит более 50 000 отказов глубинного насосного оборудования, что влечет за собой существенные финансовые потери [1] и увеличение времени простоя скважин.

При этом нефтедобывающие компании уже вложили значительные средства в цифровизацию производства, значительная часть механизированного фонда оснащена станциями управления и датчиками ТМС (системы погружной телеметрии), записывающими информацию практически в режиме реального времени, что создает предпосылки к реализации данного информационного потенциала контроля и управления ГНО [4–5]. Приоритетной задачей становится не просто контроль эксплуатационных характеристик ЭЦН, а предиктивный анализ всего массива поступающих со станции управления данных на предмет возможных технических осложнений, влекущих за собой отказ оборудования.

Таким образом, задача предиктивной аналитики заключается в своевременном выявлении предаварийного режима работы скважины для того, чтобы дать возможность скорректировать режим работы, провести профилактические мероприятия или сформировать план работ для ремонтных бригад и заранее заказать необходимое для замены оборудование.

Решить поставленную задачу предиктивной аналитики и преобразовать созданный информационный потенциал в решения, повышающие экономическую эффективность производства, могут алгоритмы машинного обучения [6].

Принципиальная схема технологии (рис. 1) предполагает последовательное выполнение ряда действий:

■ **Формирование модели данных.** На первом шаге формируется консолидированная выборка данных, характеризующая параметры эксплуатации ГНО. Выборка данных основывается на временных интервалах, включающих периоды штатной работы и периоды, характеризующиеся различными осложнениями при эксплуатации ГНО.

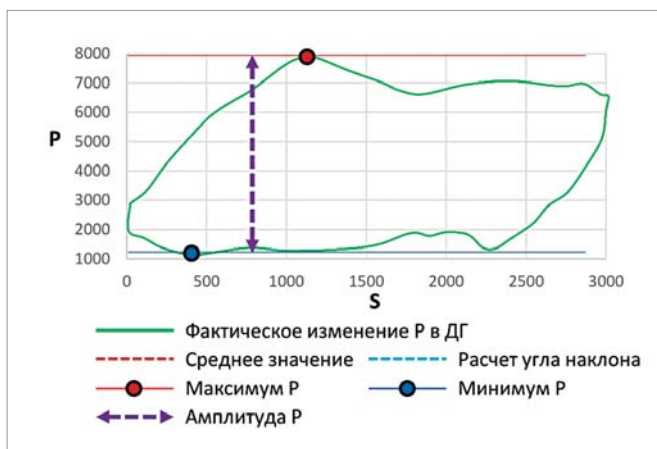
■ **Предобработка данных.** На втором шаге сформированную выборку данных необходимо преобразовать таким образом, чтобы алгоритмы искусственного интеллекта (ИИ) смогли корректно обучиться, опираясь на исторические данные и параметры эксплуатации ГНО. В этих целях первичные данные подвергают фильтрации, нормировке и стандартизации.

■ **Обучение ИИ.** На третьем этапе на основе подготовленной выборки данных (обучающая выборка) проводится обучение алгоритмов ИИ. Методы машинного обучения в зависимости от типа ГНО (ШГН или ЭЦН) различны, однако принципы обучения унифицированы и направлены в первую очередь на воспроизведение исторических параметров эксплуатации ГНО.

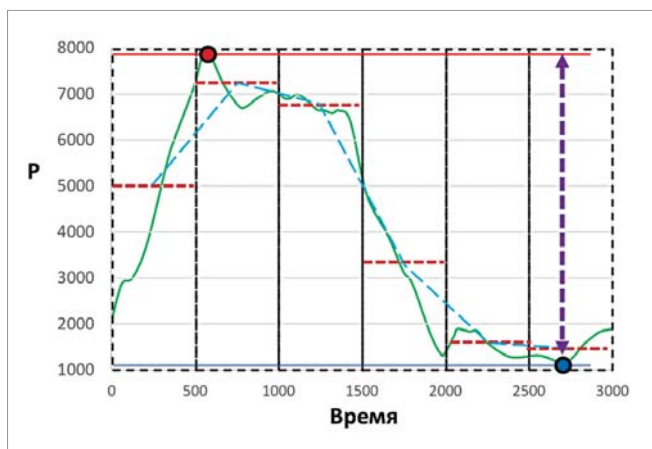
■ **Предиктивная аналитика.** На четвертом этапе уже обученные алгоритмы ИИ применяются для интерпретации



Рис. 1. Принципиальная схема технологии предиктивной аналитики



а



б

Рис. 2. Преобразование динамограммы (а) в вектор признаков (б)

данных об эксплуатации ГНО, поступающих со станций управления в режиме реального времени. Цель данного этапа – своевременно выявить осложнения в эксплуатации ГНО и оповестить ответственного специалиста о выявленном осложнении.

ФОРМИРОВАНИЕ МОДЕЛИ ДАННЫХ

Необходимым условием реализации предлагаемых решений в области предиктивной аналитики является организация системы, обеспечивающей хранение и передачу данных в режиме, максимально приближенном к режиму реального времени. В большинстве нефтегазовых компаний задача «подъема» данных из скважины и их хранения решена, однако структура хранения и сбора данных неоптимальна и реализована с применением сразу нескольких различных систем телемеханики, обеспечивающих обработку и мониторинг информации (SCADA), и станций управления, не имеющих инструментария взаимодействия друг с другом.

Для аккумулирования всех источников данных в единую базу необходимо развернуть так называемую витрину данных, функция которой заключается в сборе информации из разрозненных систем SCADA/телемеханики/станций управления и предоставлении доступа к аккумулированной первичной информации для расчетного ядра комплекса.

Перечень данных, необходимых для решения поставленной задачи, должен включать основные эксплуатационные характеристики ГНО, принципы его функционирования, а также признаки, указывающие на основные причины выхода оборудования из строя.

Для ШГН это всего два параметра, отраженных на динамограмме (рис. 2):

- нагрузка на полированный шток;
- перемещение (положение) полированного штока.

Эти параметры характеризуют поступательное движение плунжера в стволе скважины. Запись динамограмм осуществляется несколько раз в сутки, этого вполне достаточно для диагностирования большинства осложнений при эксплуатации ШГН.

Таблица 1

Параметры, характеризующие эксплуатацию центробежного насоса и погружного электродвигателя

Частота вращения	Давление на приеме насоса
Ток двигателя фазы А	Температура двигателя
Ток двигателя фазы В	Температура жидкости
Ток двигателя фазы С	Уровень виброускорения ПЭД в радиальном направлении
Дисбаланс тока	Уровень виброускорения ПЭД в осевом направлении
Ток в сети	Номинальная частота ПЭД
Напряжение в сети	Номинальный ток ПЭД
Активная мощность	Напорно-расходная характеристика
Полная мощность	Глубина спуска насоса
Входное напряжение АВ	Дебит жидкости
Входное напряжение ВС	Кэффициент мощности
Входное напряжение СА	Величина загрузки ПЭД

Для ЭЦН, ввиду более сложной конструкции, наиболее показательными считаются параметры, характеризующие эксплуатацию центробежного насоса и погружного электродвигателя (табл. 1).

ПРЕДОБРАБОТКА И ПОДГОТОВКА ДАННЫХ

Предсказательная способность моделей машинного обучения напрямую зависит от качества разметки и подготовки исходных данных [7]. Эта задача дополнительно осложнена необходимостью предварительной разметки данных на классы – штатный режим эксплуатации, осложненный режим эксплуатации. «Сырые» данные динамограмм и телеметрии не подходят для обучения моделей ввиду их зашумленности, необходимо осуществить преобразование таким образом, чтобы максимально реализовать потенциал исходной информации, не потеряв при этом в объеме данных.

Из-за разных конструктивных особенностей ЭЦН и ШГН, а также различной природы исходных данных, каждый вид глубинного насосного оборудования требует

особого подхода как при предобработке данных, так и при разработке архитектуры модели машинного обучения.

ПРЕДОБРАБОТКА ДАННЫХ. ШГН

Для ШГН принципиальным является анализ динамограмм, представляющих собой график изменения нагрузки в точке подвеса штанг в зависимости от их перемещения (длины хода станка-качалки).

Предобработка данных для работы с ШГН подразумевает формирование векторов признаков, характеризующих динамограммы работы ГНО с математической точки зрения. Такими признаками служат максимальные, минимальные значения нагрузки, амплитуда нагрузки при полном цикле хода плунжера, локальные средние значения нагрузки, скорость изменения нагрузки на различных этапах цикла и прочие (рис. 2 а, б).

Предобработка данных позволяет преобразовать каждую динамограмму, отражающую два параметра работы оборудования, в вектор данных, включающий 24 различных признака, которые впоследствии передаются в расчетное ядро для обучения ИИ в целях последующего выявления и классификации осложнений в работе оборудования.

ПРЕДОБРАБОТКА ДАННЫХ. ЭЦН

Оборудование ЭЦН более сложное и характеризуется большим числом параметров работы, из-за чего появляется необходимость в более сложной системе предобработки исходных данных.

Предобработка данных для работы с ЭЦН подразумевает не только формирование вектора признаков, характеризующих изменение параметров, полученных с датчиков телеметрии, но также и использование методов предварительной обработки первичных данных – фильтрации и нормализации.

Для формирования обучающей выборки под задачи предиктивной аналитики отказов ЭЦН критически важной является фильтрация аномальных значений, таких как единичные выбросы, нулевые значения параметров или пропуски в записи данных во время штатной работы насоса, а также показатели датчиков при выходе оборудования на режим до момента стабилизации измеряемых параметров.

Для алгоритмов машинного обучения необходимо нормировать данные на одинаковое значение, чтобы исходные данные применялись в модели в одинаковых условиях. Из-за различной природы исходных данных требуются разные подходы к нормировке параметров. Таким образом, для ЭЦН были разработаны несколько подходов к нормировке:

- расчет отклонения от номинального значения;
- расчет отклонения от стандартного значения;
- расчет степени вариативности параметров;
- выявление тренда параметра.

Помимо предобработки первичных данных, получаемых со станции управления, для работы алгоритмов машинного обучения необходимо предварительно провести разметку данных, разделив их на различные классы. Для решения задачи предиктивной аналитики отказов ЭЦН данные обучающей выборки делятся на два класса:

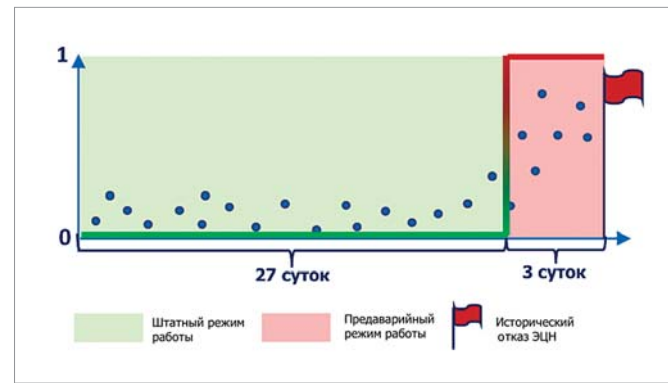


Рис. 3. Пример функции вероятности отказа ЭЦН

■ [0] – штатный режим работы. Соответствует фактическим данным эксплуатации ГНО в период штатной работы;

■ [1] – предаварийный режим работы. Соответствует показателям эксплуатации ГНО в период, предшествующий аварийному отказу. В зависимости от причины отказа данная выборка может включать данные, полученные в период до 10 дней до зафиксированного события.

Исходя из поставленной задачи обучающая выборка формируется на основе зафиксированных случаев отказов ЭЦН, для уравнивания классов штатной и предаварийной работы в обучающую выборку добавляются только данные по эксплуатации ГНО за 30 суток до зафиксированного отказа.

Таким образом, для каждого зафиксированного отказа ЭЦН, попадающего в обучающую выборку, формируется целевая функция вероятности отказа, имеющая кусочный вид и принимающая значение от 0 (штатная работа установки) до 1 (аварийная работа установки) (рис. 3).

При этом следует отметить, что часть зафиксированных отказов ЭЦН не поступает в обучение ИИ, а используется впоследствии для оценки метрики точности обучения модели. В обучающую выборку направляются данные о 80 % всех событий отказов ЭЦН, в тестовую – о 20 %.

На следующем этапе ставится задача с помощью алгоритмов машинного обучения получить функциональную зависимость между набором первичных параметров эксплуатации установки ЭЦН и функцией вероятности отказа.

ОБУЧЕНИЕ ИИ

Ввиду значительного отличия компоновок ЭЦН и ШГН, а также различных принципов их работы, компоненты ИИ для ЭЦН и ШГН тоже несколько отличаются. Для ШГН расчетное ядро формируется на основе классических алгоритмов машинного обучения [10], для ЭЦН – на основе рекуррентной нейронной сети [8, 9].

РАСЧЕТНОЕ ЯДРО ШГН

Расчетное ядро для предсказания отказов ШГН представляет собой алгоритм машинного обучения, адаптированный для решения задачи классификации штатных режимов и режимов, характеризующихся различными осложнениями при работе ШГН.

В целях повышения объективности результатов расчетов были разработаны следующие принципы формирования выборок:

Генеральная выборка данных формируется таким образом, чтобы в обучающую и тестовую выборки данных не попадала одна и та же скважина. Динамограммы, полученные на одной и той же скважине, не должны находиться одновременно и в обучающей, и в тестовой выборке, поскольку графики изменения параметров эксплуатации данной скважины могут быть практически идентичны и, следовательно, точность расчетов, проведенных с использованием данных тестовой выборки, может быть искусственно завышенной.

Данные генеральной выборки делятся на обучающие и тестовые в соотношении четыре к одному. Данные тестовой выборки не участвуют в обучении модели ИИ.

Характерные особенности исходных данных обусловили выбор «классических» алгоритмов машинного обучения, в данном случае наиболее подходящим является RandomForest [10].

Для тестирования обученной модели ИИ была выбрана стандартная метрика, определяющая точность идентификации событий на тестовой выборке данных, не участвующей в процессе обучения. Метрика определяется отношением правильно идентифицированных на тестовой выборке режимов работы скважины (TP) к общему числу событий – как верно идентифицированных (TP), так и ложно (FP):

$$\text{Метрика(ЭЭЦН)} = \frac{TP}{TP + FP + TN} \cdot 100 \%$$

По результатам тестирования значение метрики превысило 90 %. Пример интерпретации динамограмм представлен на рис. 4, метрика идентификации событий приведена в табл. 2.

РАСЧЕТНОЕ ЯДРО ЭЦН

Для решения задач предиктивной аналитики отказов ЭЦН ввиду сложной конструкции ГНО и большого объема данных применялись алгоритмы машинного обучения, основанные на нейронных сетях. Архитектура применяемой нейронной сети была выстроена на основе рекуррентных слоев нейронов [8–9]. Такой выбор архитектуры обусловлен характером исходных данных, имеющих природу временных векторов.

Процесс обучения нейронной сети носил итерационный характер и заключался в поиске оптимального варианта распределения весовых коэффициентов, обеспечивающих максимизацию предсказательной способности алгоритма на тестовой выборке.

В качестве метрики, характеризующей эффективность работы алгоритма, была принята метрика, описывающая соотношение верно выявленных отказов на тестовой выборке (TP) и общего числа отказов – как выявленных алгоритмом (TP), так и невыявленных (FP), а также количества ложно выявленных отказов на тестовой выборке (TN):

$$\text{Метрика(ЭЦН)} = \frac{TP}{TP + FP + TN} \cdot 100 \%$$

При этом в качестве критерия выявленного отказа на тестовой выборке (TP) было принято условие превышения функцией вероятности отказа (рис. 5 а, б), генерируемой ИИ, границы аварийного состояния. Для функции вероятности отказа эта граница определена на уровне 0,3. Соответственно если функция вероятности на тестовых данных, характеризующих предаварийное состояние, превышает значение 0,3, то считается, что отказ был определен верно (TP), в ином случае отказ не выявлен (TF). В метрику включены также случаи ложного выявления события, определено это условием превышения функцией

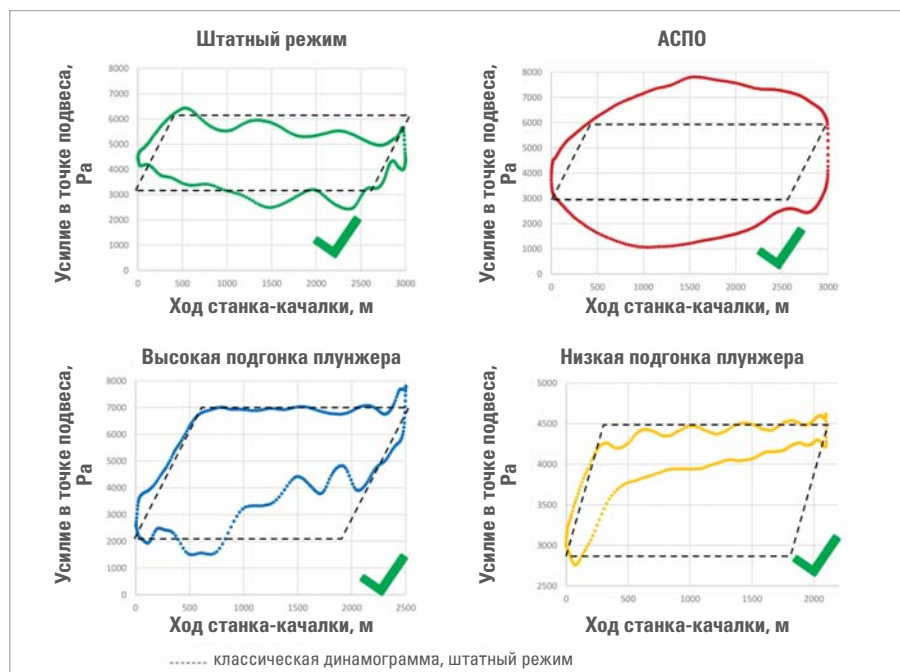
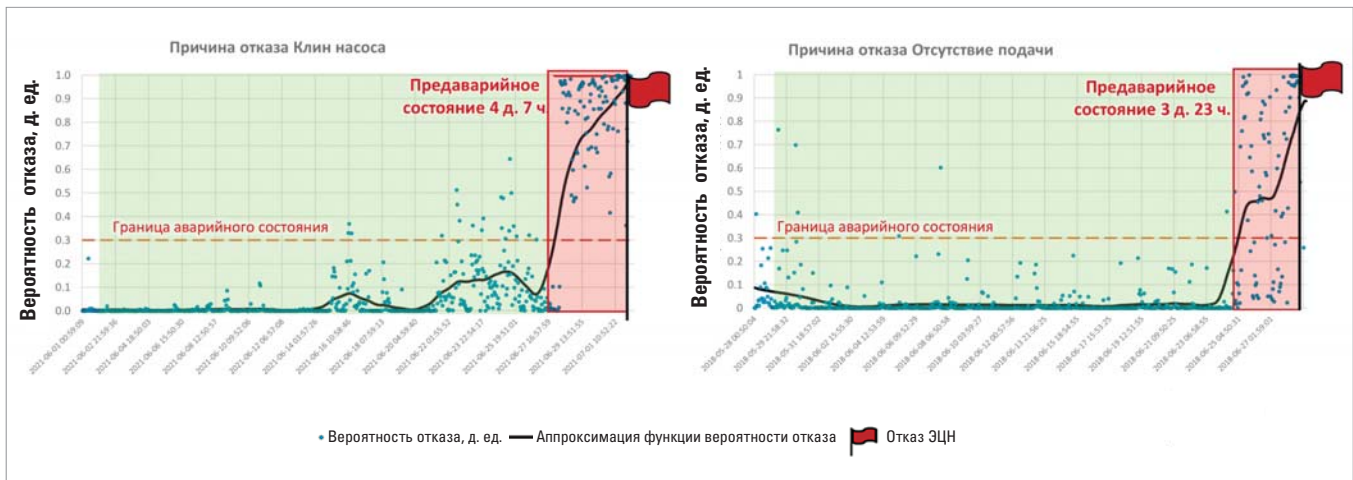


Таблица 2
Метрика точности

Класс	Достигнутая точность, %
Штатный режим	94
АСПО	81
Высокая подгонка	93
Низкая подгонка	94
В целом	90

Рис. 4
Пример автоматической интерпретации динамограмм



а **б**
Рис. 5. Оценка метрики точности на данных тестовой выборки:
 а – причина отказа – клин насоса; б – причина отказа – отсутствие подачи

вероятности отказа порогового значения 0,3 на исторических данных, характеризующих штатную работу ЭЦН (ТМ).

Качество обучения ИИ проверяется на данных тестовой выборки, не участвующих в обучении. Оценка точности предсказания модели ИИ, согласно метрике, достигла значения в 80 %, что характеризует модель как обученную и пригодную для применения в рамках выполнения работ по предиктивной аналитике отказов. Примеры работы ИИ на тестовой выборке представлены на рис. 5 а (причина отказа – клин ЭЦН) и 5 б (отсутствие подачи).

ПРЕДИКТИВНАЯ АНАЛИТИКА

Разработанные алгоритмы предиктивной аналитики, реализованные в ПО «АТЛАС – Диспетчер скважин», показывают высокую метрику точности на тестовой выборке, что позволило перейти на стадию опытно-промышленных испытаний технологии. В настоящее время ОПИ ведутся на трех участках АО «НК «Нефтиса». Предварительные результаты тестирования алгоритма на 137 добывающих скважинах, оснащенных ЭЦН: за период тестирования (7 месяцев) произошло 18 отказов ЭЦН, алгоритм успешно смог выявить 13 отказов, опытно-промышленные испытания технологии продолжаются.

Промышленное применение алгоритмов предиктивной аналитики отказов невозможно без обеспечения прямого доступа к первичной информации об эксплуатационных характеристиках ГНО. В этих целях разрабатывается протокол подключения программного обеспечения «АТЛАС – Диспетчер скважин» напрямую к системам телеметрии нефтедобывающего предприятия, что в дальнейшем позволит в режиме реального времени проводить предиктивную аналитику состояния ГНО.

Концепция предлагаемого промышленного применения алгоритмов предиктивной аналитики предполагает непрерывный контроль эксплуатационных характеристик ГНО на предмет выявления осложнений и предаварийного состояния оборудования. В момент выявления осложне-

ний программное обеспечение передает сигнал на пульт управления системой, где оператор принимает решение о проведении профилактических мероприятий в целях снижения риска отказа ГНО.

Интерфейс программного обеспечения «АТЛАС – Диспетчер скважин» предполагает трехуровневую систему представления информации (рис. 6). Первый уровень предусматривает визуализацию всего участка (ЦДНГ) с выделением кустовых площадок, где имеется цветовая индикация скважин, режим которых идентифицирован как штатный (зеленый цвет) и как предаварийный (красный цвет). Второй уровень предполагает более детальное рассмотрение данных по кустовой площадке в целом, на данном уровне выводится текущая информация об эксплуатационных характеристиках ГНО. На третьем уровне представлена детальная информация о показателях эксплуатации отдельных скважин, что позволяет проводить ретроспективный анализ изменения режимов эксплуатации ГНО.

Программное обеспечение «АТЛАС – Диспетчер скважин» является одним из модулей технологической платформы «Атлас» (рис. 7), консолидирующей решения в области подсчета запасов, мониторинга разработки месторождений, технико-экономической оценки, экспертизы 3D геолого-гидродинамических моделей и искусственного интеллекта применительно к задачам управления производственными процессами и повышения эффективности добычи нефти.

Технологическая платформа «Атлас» за счет консолидации решений в различных областях нефтедобычи обеспечивает синергетический эффект. Указанный эффект достигается благодаря интеграции смежных технологий, таких как нейросетевые технологии управления добычей [2–3, 11–14] и технология предиктивной аналитики отказов.

Задача нейросетевых технологий управления добычей [2–3, 11–14] – повышение эффективности разработки за счет оптимизации системы заводнения с помощью алгоритмов искусственного интеллекта. Основной объект

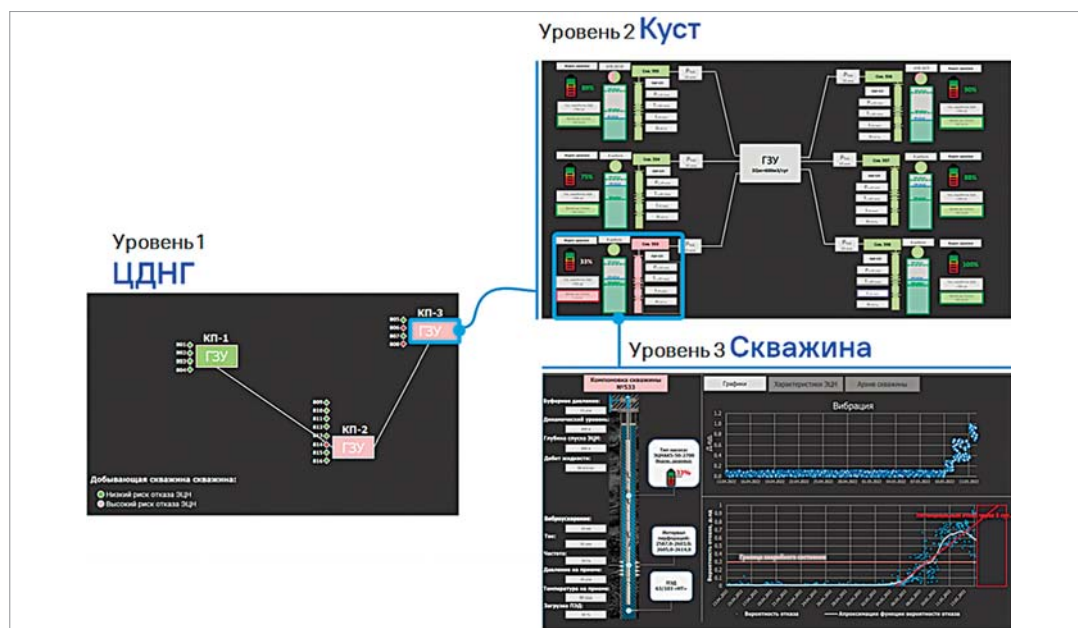


Рис. 6. Интерфейс программы «АТЛАС – Диспетчер скважин»

воздействия данных технологий – нагнетательный фонд. Автоматизировать процесс обеспечения оптимальных режимов эксплуатации нагнетательных скважин в парадигме нейросетевой оптимизации позволяет программный модуль «АТЛАС-АСУ», также входящий в состав технологической платформы «Атлас». В меньшей степени эти технологии затрагивают эксплуатацию механизированного фонда.

Технология предиктивной аналитики отказов фокусируется на контроле эксплуатационных характеристик механизированного фонда скважин. Основной ее задачей

является своевременное выявление осложнений при эксплуатации ГНО. Данная технология не имеет отношения к нагнетательному фонду.

Технологии нейросетевого управления добычей и предиктивной аналитики отказов, гармонично дополняя друг друга, с одной стороны, обеспечивают оптимизацию системы заводнения, с другой – повышают оперативность выявления осложнений при эксплуатации ГНО, увеличивая тем самым время наработки на отказ. Таким образом, благодаря синергии технологий повышается эффективность разработки (рис. 8). Интеграция данных технологий в цифровой



Рис. 7. Технологическая платформа «Атлас»

контур компании обеспечивает реализацию проекта интеллектуального месторождения, основанного на концепции управления промыслом с помощью алгоритмов машинного обучения, что позволяет как обеспечить рост добычи нефти за счет оптимизации режимов работы нагнетательных скважин, так и сократить время простоя добывающего фонда.

ВЫВОДЫ

Алгоритмы машинного обучения все активнее внедряются в практику работы нефтяных компаний. Элементы искусственного интеллекта в рамках представленных алгоритмов помогают своевременно диагностировать осложнения при эксплуатации ГНО, повышая тем самым оперативность реагирования служб промысла и снижая

вероятность отказов оборудования. Разработанное программное обеспечение «АТЛАС – Диспетчер скважин» является частью технологической платформы «Атлас», созданной для прогнозирования отклика добывающих скважин на закачку агента и определения оптимальной конфигурации режимов эксплуатации скважин. Совместное применение данного ПО с технологией нейросетевого управления добычей обеспечивает синергетический эффект, позволяет вывести скважины на оптимальные режимы эксплуатации, снижая при этом риски простоя скважин из-за отказов ГНО.

Разработанная технология является еще одним шагом к осмысленной цифровизации месторождения и реализации потенциала интеллектуального управления.



Рис. 8. Концепция управления промыслом на основе алгоритмов машинного обучения

ИСПОЛЬЗОВАННЫЕ ИСТОЧНИКИ

1. Камалетдинов, Р.С. Механизированная добыча нефти: новые вызовы – новые решения / Р.С. Камалетдинов // Neftegaz.ru. – 2023. – № 4. – URL: <https://magazine.neftegaz.ru/>. – Дата публикации: 12.04.2023.
2. Бриллиант, Л.С. Архитектура цифровых решений управления режимами эксплуатации скважин в задачах эффективной разработки зрелых месторождений нефти / Л.С. Бриллиант, М.Р. Дулкарнаев, М.Ю. Данько [и др.] // Недропользование XXI век. – 2020. – № 4. – С. 98–102.
3. Рябец, Д.А. Управление добычей на основе нейросетевой оптимизации режимов работы скважин на объекте БС₈ Западно-Малобалыкского месторождения / Д.А. Рябец, В.В. Бескурский, Л.С. Бриллиант [и др.] // Neftegaz.ru. – 2019. – № 9. – URL: <https://magazine.neftegaz.ru/>. – Дата публикации: 24.06.2023.
4. Хоноре, Т. Цифровизация нефтяной промышленности: базовые подходы и обоснование интеллектуальных технологий / Тчаро Хоноре, А.Е. Воробьев, К.А. Воробьев // Вестник Евразийской науки. – 2018. – № 2. – Т. 10. – С. 1–17.
5. Козлова, Д.В. Интеллектуальная добыча / Д.В. Козлова, Д.Ю. Пигарев // Neftegaz.ru. – 2018. – № 9. – URL: <https://magazine.neftegaz.ru/>. – Дата публикации: 07.02.2020.
6. Кучин, В.Н. Повышение экономической эффективности разработки нефтегазовых месторождений на основе внедрения цифровых инструментов / В.Н. Кучин, Е.Ю. Гарбуз // Neftegaz.ru. – 2023. – № 6. – URL: <https://magazine.neftegaz.ru/>. – Дата публикации: 26.12.2023.
7. Быков, К.В. Особенности преобработки данных для применения машинного обучения / К.В. Быков // Молодой ученый. – 2021. – № 53. – С. 1–4.
8. Бендерская, Е.Н. Рекуррентная нейронная сеть как динамическая система и подходы к ее обучению / Е.Н. Бендерская, К.В. Никитин // Научно-технические ведомости СПбГПУ. – 2013. – № 4. – С. 29–37.
9. Обуров, М.О. Применение LSTM-сети в решении задачи прогнозирования многомерных временных рядов / М.О. Обуров, С.Ю. Кириллова // Национальная ассоциация ученых (НАУ). – 2021. – № 68. – С. 45–49.
10. Katser, I. Online Forecasting and Anomaly Detection Based on the ARIMA Model / I. Katser, V. Kozitsin, D. Lakontsev // Open Access Journal by MDPI. – 2021. – С. 11–24.
11. Автоматизация процессов управления режимами работы нагнетательных скважин при нейросетевой оптимизации на объекте БС₈ Западно-Малобалыкского месторождения / Л.С. Бриллиант, Д.В. Горбунова, А.С. Завьялов [и др.] // Neftegaz.ru. – 2020. – № 2. – URL: <https://magazine.neftegaz.ru/>. – Дата публикации: 27.02.2020.
12. Управление заводнением нефтяных месторождений на основе прокси-моделирования / А.А. Потрясов, М.Р. Мазитов, С.С. Никифоров [и др.] // Нефть. Газ. Новации. – 2014. – № 12. – С. 32–37.
13. Бриллиант, Л.С. Формализованный подход к управлению заводнением нефтяного месторождения / Л.С. Бриллиант, А.И. Комягин // Нефть. Газ. Новации. – 2016. – № 22. – С. 66–72.
14. Методические основы и опыт внедрения цифровых технологий оперативного планирования и управления режимами работы добывающих и нагнетательных скважин на участке ОПР пласта ЮВ, Ватьеганского месторождения ТПП «Повхнефтегаз» (ООО «ЛУКОЙЛ-Западная Сибирь») / С.В. Арефьев, Р.Р. Юнусов, А.С. Валеев [и др.] // Недропользование XXI век. – 2017. – № 6. – С. 60–82.