

© Коллектив авторов,
2025



УДК 622.692.4.05:681.518.5
<https://doi.org/10.51890/2587-7399-2025-10-2-132-143>

РАЗРАБОТКА И ПРИМЕНЕНИЕ ИНСТРУМЕНТА ПРОГНОЗИРОВАНИЯ ОСТАТОЧНОГО РЕСУРСА ТРУБОПРОВОДОВ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

**А.Ф. Садыков¹, Б.И. Мухаметзянов¹, М.В. Черняк¹, Д.В. Батрашкин²,
Р.А. Абдуллаев^{2,*}, Р.Ф. Гимазетдинов², У.М. Саттаров²**

¹ООО «Недра», РФ, Санкт-Петербург

²Группа компаний «Газпром нефть», РФ, Ханты-Мансийск

Электронный адрес: abdullaev.ra@hantos.gazprom-neft.ru

Введение. Статья посвящена актуальной проблеме мониторинга состояния промышленных трубопроводов в нефтегазовой отрасли, где коррозионные дефекты существенно влияют на эффективность их эксплуатации. Традиционные методы оценки состояния трубопроводных сетей, такие как внутритрубная диагностика и коррозионные свидетели, имеют технологические и экономические ограничения. В данной работе предложен новый подход, основанный на применении методов машинного обучения для прогнозирования роста дефектов на основе ретроспективных данных.

Цель исследования — разработка инструмента прогнозирования остаточного ресурса трубопроводов на основе методов машинного обучения, который позволит повысить эффективность управления целостностью трубопроводов. Основная задача — создание алгоритма, позволяющего прогнозировать появление и развитие коррозионных дефектов, что способствует повышению надежности трубопроводного транспорта, снижению эксплуатационных затрат и оптимизации процессов технического обслуживания.

Материалы и методы. В исследовании использованы данные о техническом состоянии трубопроводов, включая результаты внутритрубной диагностики (ВТД), ультразвуковой толщинометрии (УЗТ), а также эксплуатационные параметры. Для анализа и прогнозирования применены следующие методы машинного обучения: градиентный бустинг (CatBoost), AutoML, LSTM и Transformer. Предварительная обработка данных для этих методов включала отбор ключевых параметров с помощью корреляционного анализа Пирсона и метода главных компонент (PCA). Данные были разделены на обучающую и тестовую выборки, а эффективность методов оценивалась по метрике средней абсолютной ошибки (MAE).

Результаты. Проведено сравнение различных алгоритмов машинного обучения при прогнозировании глубины коррозионных дефектов трубопроводов. Наилучший результат показала модель, основанная на градиентном бустинге с использованием архитектуры Transformer.

Заключение. Разработанный инструмент обеспечивает раннее выявление дефектов, автоматизированный углубленный анализ больших массивов данных и поддержку принятия решений. Внедрение данного подхода в процессы эксплуатации позволяет снизить затраты на диагностику и ремонты, а также повысить безопасность эксплуатации нефтепромысловых трубопроводов. Инструмент может быть интегрирован в системы управления техническим состоянием трубопроводов, обеспечивая эффективное прогнозирование и планирование ремонтных мероприятий.

Ключевые слова: прогнозирование ресурса, коррозионные дефекты, машинное обучение, предиктивная аналитика, градиентный бустинг

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Для цитирования: Садыков А.Ф., Мухаметзянов Б.И., Черняк М.В., Батрашкин Д.В., Абдуллаев Р.А., Гимазетдинов Р.Ф., Саттаров У.М. Разработка и применение инструмента прогнозирования остаточного ресурса трубопроводов с использованием методов машинного обучения. ПРОНЕФТЬ. Профессионально о нефти. 2025;10(2):132–143. <https://doi.org/10.51890/2587-7399-2025-10-2-132-143>

Статья поступила в редакцию 02.03.2025

Принята к публикации 01.04.2025

Опубликована 30.06.2025

DEVELOPMENT AND APPLICATION OF A PIPELINE REMAINING LIFE PREDICTION TOOL USING
MACHINE LEARNING METHODS

**Azamat F. Sadykov¹, Bulat I. Mukhametzyanov¹, Mikhail V. Chernyak¹, Dmitry V. Batrashkin²,
Rafael A. Abdullaev^{2,*}, Ramis F. Gimazetdinov², Ural M. Sattarov²**

¹Nedra LLC, RF, Saint Petersburg

²Gazprom нефт company group, RF, Khanty-Mansiysk

E-mail: abdullaev.ra@hantos.gazprom-neft.ru

Introduction. This paper addresses the urgent problem of monitoring the condition of field pipelines in the oil and gas industry, where corrosion defects significantly affect operational efficiency. Traditional methods of assessing pipeline networks, such as in-line inspection and corrosion coupons, have technological and economic limitations. This study proposes a novel approach based on machine learning methods to predict defect growth using retrospective data.

Objective. The aim of the research is to develop a pipeline remaining life prediction tool based on machine learning methods to improve pipeline integrity management. The main task is to create an algorithm capable of forecasting the emergence and development of corrosion defects, thereby enhancing the reliability of pipeline transport, reducing operational costs, and optimizing maintenance processes.

Materials and methods. The study utilized data on the technical condition of pipelines, including results from in-line inspection (ILI), ultrasonic thickness measurements (UTM), and operational parameters. The following machine learning methods were applied for analysis and forecasting: gradient boosting (CatBoost), AutoML, LSTM, and Transformer. Data preprocessing included the selection of key parameters using Pearson correlation analysis and principal component analysis (PCA). The data was split into training and test sets, and the effectiveness of the methods was evaluated using the Mean Absolute Error (MAE) metric.

Results. A comparative analysis of various machine learning algorithms was conducted to predict the depth of corrosion defects in pipelines. The best performance was demonstrated by the model based on gradient boosting combined with a Transformer architecture.

Conclusion. The developed tool enables early defect detection, automated in-depth analysis of large datasets, and decision-making support. Implementing this approach in operational processes helps reduce inspection and repair costs and improves the safety of oilfield pipeline operations. The tool can be integrated into pipeline condition management systems to provide effective forecasting and maintenance planning.

Keywords: remaining life prediction, corrosion defects, machine learning, predictive analytics, gradient boosting

Conflict of interest: the authors declare that they have no conflict of interest.

For citation: Sadykov A.F., Mukhametzyanov B.I., Chernyak M.V., Batrashkin D.V., Abdullaev R.A., Gimazetdinov R.F., Sattarov U.M. Development and application of a pipeline remaining life prediction tool using machine learning methods. PRONEFT. Professionally about oil. 2025;10(2):132–143. <https://doi.org/10.51890/2587-7399-2025-10-2-132-143>

Manuscript received 02.03.2025

Accepted 01.04.2025

Published 30.06.2025

ВВЕДЕНИЕ

Ключевой целью в области добычи и транспортировки нефти является повышение эффективности производства и оптимизация операционных затрат. Одним из важных факторов, который влияет на эффективность транспортировки продукции, является отказ трубопроводов, вызванный коррозионными дефектами.

Для повышения износостойкости трубопроводов на них регулярно проводится оценка их состояния, что позволяет определить наличие и степень влияния коррозионных дефектов и оценить остаточного ресурса.

Существующие на сегодня методы оценки остаточного ресурса нефтегазовых трубопроводов основываются на проведении прямых инструментальных измерений коррозионных дефектов на различных участках и в разные моменты времени с использованием внутритрубной диагностики (ВТД) и ультразвуковой толщинометрии (УЗТ). Однако эти методы не позволяют охватить всю сеть трубопроводного транспорта из-за наличия технических ограничений, а также отсутствия экономической целесообразности. Вследствие этого возникает необходимость внедрять другие экономически эффективные подходы

для мониторинга и оценки состояния трубопроводов, которые дадут возможность не только сопоставлять разновременные проведенные ВТД и УЗТ, но и будут включать в себя алгоритмы подбора трубопроводов — аналогов.

По этой причине становится все более актуальной задача разработки эффективного инструмента для мониторинга технологического состояния промышленных трубопроводов и поддержки принятия решений при формировании программ повышения надежности объектов трубопроводного транспорта за счет использования огромного массива ретроспективных данных и технологии машинного обучения.

**НА ОСНОВЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ
ДЛЯ МОНИТОРИНГА СОСТОЯНИЯ ПРОМЫСЛОВЫХ
ТРУБОПРОВОДОВ И ИХ ОСТАТОЧНОГО РЕСУРСА
РАЗРАБОТАН ИНСТРУМЕНТ, ПОЗВОЛЯЮЩИЙ ПОВЫСИТЬ
ЭФФЕКТИВНОСТЬ УПРАВЛЕНИЯ ИХ ЦЕЛОСТНОСТЬЮ.**

Цель работы — создание алгоритма на основе моделей машинного обучения, описывающего прогнозные зарождение новых и увеличение глубины ранее обнаруженных коррозионных дефектов, что позволит



Рис. 1. Классификация методов оценки остаточного ресурса трубопровода.
Составлено авторами
Fig. 1. Classification of pipeline remaining life assessment methods.
Compiled by the authors

в дальнейшем понимать техническое состояние трубопроводов в различных условиях эксплуатации в средне- и долгосрочной перспективе.

Данный алгоритм важен при планировании программы обеспечения целостности трубопровода и позволяет снизить затраты, связанные с повторным диагностированием.

Таблица 1. Соответствие методики определения величины ОР трубопровода и нормативной документации. Составлено авторами
Table 1. Correspondence between pipeline remaining life assessment methods and regulatory documentation. Compiled by the authors

№	Наименование методики	Нормативный документ
1	Линейная модель роста дефекта	API 570 [4]
		РД-23.040.00-КТН-011 [3]
		М-01.06.06-04 [1]
2	Нелинейная модель роста дефекта	DNV-RP-F101 [9]
3	Гамма-процентный остаточный ресурс	ОСТ 153-39.4-010-2002 [15]
4	Марковский процесс чистого рождения/гибели	-
5	Стохастическое моделирование	-

ОБЗОР СУЩЕСТВУЮЩИХ МЕТОДОВ ОПРЕДЕЛЕНИЯ ОСТАТОЧНОГО РЕСУРСА ТРУБОПРОВОДОВ

Остаточный ресурс (ОР) — это время эксплуатации трубопровода от момента определения его технического состояния (последней диагностики) до перехода в предельное состояние [1]. В свою очередь, предельное состояние трубопровода — это техническое состояние трубопровода, при котором исключена его дальнейшая эксплуатация. Подобное состояние наступает в результате превышения в трубопроводе рабочего давления над максимально допустимым (с учётом дефектов) [2] или увеличение глубины дефекта при рабочем давлении до предельного значения [3].

Задача определения величины ОР нефтесборных сетей состоит в том, чтобы дать оценку оставшегося срока службы нефтепровода, используя результаты диагностики (единственной или их последовательности), и соответственно параметры дефектов в определенные моменты времени. В свою очередь, исходные значения параметров дефектов определяются по данным ВТД и УЗТ. Прогнозирование будущего технического состояния трубопровода основано на прогнозных значениях размеров дефектов, увеличивающихся во времени. Согласно анализу научно-технической литературы, прогнозные значения размеров дефектов определяются по величине скорости роста дефектов [1–21], что приводит к необходимости совмещения (сопоставления) дефектов разновременных диагностических обследований.

Согласно [9], расчетные методы оценки величины ОР трубопровода [2, 6–7, 8, 15, 16] разделяются на детерминированные и вероятностные. Детерминированные методы, в свою очередь, подразделяются на линейную [2–4] и нелинейную [8, 9] модели, в зависимости от скорости развития коррозионного дефекта. Вероятностными методами являются: гамма-процентный остаточный ресурс (ГПОР) [6–7, 13], марковский процесс чистого рождения или гибели [9, 11], стохастическое моделирование [16]. Классификация методов представлена на **рис. 1**. Соответствие методов определения величины ОР трубопровода и нормативной документации (НД) представлено в **табл. 1**.

Основные преимущества и недостатки основных методик оценки остаточного ресурса трубопровода представлены в **табл. 2**. Таким образом, существующие традиционные подходы к оценке остаточного ресурса учитывают ограниченное число факторов,

Таблица 2. Сравнение методик оценки величины остаточного ресурса трубопровода. Составлено авторами
Table 2. Comparison of pipeline remaining life assessment methods. Compiled by the authors

№	Наименование группы методики	Область применения	Преимущества	Недостатки
1	Линейная модель роста дефекта	Линейные участки трубопроводов	- закреплена в международных стандартах [2–4]; - применяются элементарные вычислительные процессы	- требует высокий уровень достоверности исходных данных [4]; - не учитывает случайный рост параметров дефектов
2	Нелинейная модель роста дефекта	Линейные участки трубопроводов из углеродистой стали	- закреплена в международных стандартах [9]; - применяются элементарные вычислительные процессы; - учитывается материал грунта и трубы	- требует высокий уровень достоверности исходных данных [4]; - не учитывает случайный рост параметров дефектов [29]
3	Гамма-процентный остаточный ресурс	Нефтегазовые промышленные трубопроводы и трубопроводы головных сооружений нефтяных месторождений	- закреплена в отечественном отраслевом стандарте [15]; - применяются элементарные вычислительные процессы	- не учитывает случайный рост параметров дефектов
4	Марковский процесс чистого рождения/гибели	Линейные участки трубопроводов	- учитывается исходная статистическая информация о параметрах начальных дефектов [29]	- требует начальные данные по распределению вероятностей глубины дефекта; - длительные и трудоемкие вычислительные процессы; - при увеличении диапазона разброса исходных данных увеличивается значение отклонения результатов
5	Стохастическое моделирование	Линейные участки трубопроводов	- погрешность измерения оборудования представлена случайной величиной; - учитывает случайный рост параметров дефектов [29]	- длительные и трудоемкие вычислительные процессы [29]; - при увеличении диапазона разброса исходных данных увеличивается значение отклонения результатов [11]

что не позволяет достоверно оценивать рост глубины коррозионных дефектов в будущем и эффективно реализовать запланированную программу надёжности трубопроводов. В свою очередь, применение моделей машинного обучения в анализе остаточного ресурса позволяет значительно ускорить процесс принятия решений, т.к. модели обучаются на большом массиве ретроспективных параметров, что дает возможность предсказать потенциальные участки с высоким риском коррозии и быстро оценить степень повреждений.

Кроме того, анализ с использованием машинного обучения учитывает не только текущие данные, но и динамические изменения, такие как изменения в давлении, температуре и химическом составе среды. Это создает дополнительный уровень защиты при управлении рисками, поскольку позволяет прогнозировать и управлять возможными последствиями, основанными на реальных и актуальных данных, а не только на усредненных расчетах или статистических моделях.

АЛГОРИТМЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ ОСТАТОЧНОГО РЕСУРСА ТРУБОПРОВОДА

Физическое моделирование множества взаимодействующих между собой рабочих параметров представляет собой значительные сложности при разработке эффективных

прогнозных моделей. В связи с этим использование комбинации алгоритмов машинного обучения (ML) и традиционных методов оценки остаточного ресурса значительно упрощает создание физической модели и повышает точность оценки остаточного ресурса трубопроводов.

Первым и ключевым шагом в разработке эффективного алгоритма машинного обучения является сбор и анализ необходимых входных регулярно измеряемых параметров, поскольку качество и полнота исходной информации напрямую определяют его производительность.

Для оценки функциональности разработанных в рамках данной работы моделей использованы обезличенные промышленные данные нефтегазосборных сетей трубопроводов компании «Газпромнефть-Хантос».

Объектами исследования являются трубопроводы нефтегазосборных сетей и напорные нефтепроводы.

Объем предоставленных данных представлен в табл. 3.

Определение ключевых параметров является важным этапом анализа, позволяя выявить характеристики, оказывающие наибольшее влияние на место и скорость образования дефектов. На первоначальном этапе отбора использовались методы фильтрации, основанные на экспертной оценке значимости параметров. В ходе этого процесса были исключены несущественные, дублирующиеся и некорректные признаки, а также отдельные

Таблица 3. Набор данных, использованный для обучения моделей.

Составлено авторами

Table 3. Dataset used for model training. Compiled by the authors

Категория	Число записей
Технологический режим трубопроводов	~ 40 000 000
Результаты ВТД	~ 900 000
Результаты УЗТ	~ 400 000
Высотные отметки трубопроводов	~ 1 200 000
Данные о ремонтах трубопроводов	~ 1000
Физико-химические свойства сред	~ 10 000
Коррозионный мониторинг	~ 100 000

записи, такие как: несовпадающие в разных источниках данные о физических параметрах трубопроводов, отсутствие информации о технологическом режиме работы трубопровода, а также записи, возникающие вследствие ошибок при сборе данных или многократного внесения одинаковой информации, что могло бы исказить результаты анализа. На следующем этапе исследования для выбора входных переменных применялся корреляционный анализ Пирсона [17], позволяющий измерить степень линейной связи между признаками. По его результатам была

построена тепловая карта (рис. 2), которая использовалась для визуализации взаимосвязей между параметрами. Крайне темные и светлые квадраты на пересечении признаков свидетельствуют о сильной линейной корреляции (значения близкие к 1 или -1), что указывает на возможность прогнозирования одного параметра на основе другого. В таких случаях из группы высокоррелированных признаков оставался только один, чтобы минимизировать избыточность данных и повысить эффективность обучения модели. После переработки и рекомбинации исходных параметров формировался сокращенный набор признаков, содержащий наиболее ценную информацию.

Для обучения и оценки точности прогнозирования алгоритмов исходный набор данных был разделен на тренировочную выборку (80 % общего объема данных) и тестовую выборку (20 %).

Сеть трубопроводов, в свою очередь, была разбита на сегменты, для каждого из которых использовались данные о высотных отметках. Каждый сегмент затем делился на отрезки длиной 1 м, на которых оставался только один дефект с максимальной глубиной по результатам ВТД и/или УЗТ. Трубопроводы были разделены по идентификационному номеру (ID) отдельных участков,




Рис. 2. Корреляционная карта параметров по Пирсону. Составлено авторами

Fig. 2. Pearson correlation heatmap of parameters. Compiled by the authors

что предотвратило утечку информации о распределениях признаков в тестовом наборе данных, обеспечив тем самым корректную оценку способности модели к обобщению и ее общей производительности.

Технологический режим работы трубопроводов был сжат с помощью эмбедингов, которые кодируют данные о записях соответствующего сегмента.

Модификация входных параметров и гиперпараметрических атрибутов ML осуществлялась с применением метода главных компонент (principal component analysis — PCA).

Цель данной модификации — улучшение качества модели за счёт преобразования признаков в некоррелированное пространство, при этом ещё выполняется устранение избыточности и шума. Это позволяет алгоритму лучше улавливать важные зависимости, улучшая численную стабильность и качество прогноза.

В ходе работы выполнялся процесс генерации и отбора новых признаков, которые были созданы на основе исходных данных. Эти признаки получены через различные взаимодействия между исходными признаками, а также с использованием статистических и математических операций и их комбинаций. Такие признаки помогают алгоритму выявлять более сложные зависимости, что повышает точность предсказаний. Этот подход способствует увеличению информативности признаков и улучшает способность алгоритма выявлять скрытые закономерности.

Целевым параметром прогноза является глубина коррозионного дефекта для каждого метрового сегмента участка трубопровода. Расчет основывается на условиях эксплуатации, которые преобладают в течение промежутков времени между различными последовательными событиями:

- ввод в эксплуатацию;
- проведение диагностики;
- ремонты;
- отказы.

Предполагается, что поведение трубопровода соответствует ретроспективной информации о рабочих параметрах и глубине замеченных коррозионных дефектов.

Таким образом, рост дефекта будет моделироваться в соответствии с уравнениями (1), (2).

$$\begin{cases} IDD(t) = f_{\sigma} [X_1(t), X_2(t), \dots, X_i(t)], \\ TDD(t) = \sum_{i=1}^T IDD_i, i = 1, 2, \dots \end{cases} \quad (1)$$

где IDD — расчетная глубина дефекта, TDD — совокупные значения IDD , $X_1(t)$, $X_2(t)$, ..., $X_i(t)$ представляет рабочие параметры трубопровода в данный момент времени t , T — совокупное время, а f_{σ} представляет собой

используемую ML с исходными или модифицированной параметрами и гиперпараметрами.

Глубина коррозионного дефекта в каждом конкретном случае моделировалась как нелинейная сложная динамическая система, которая зависит от эксплуатационных характеристик и их взаимодействия. Влияние микробиологических организмов, таких как сульфатовосстанавливающие бактерии (СВБ), не учитывалось из-за их отсутствия в системе сбора и транспортировки компании «Газпромнефть-Хантос».

В данной работе приведена оценка эффективности прогнозирования остаточного ресурса следующих алгоритмов машинного обучения:

- градиентный бустинг [18];
- AutoML [19];
- градиентный бустинг с LSTM [20];
- классические методы с LSTM, PCA и генерацией признаков;
- градиентный бустинг с LSTM, PCA и генерацией признаков;
- градиентный бустинг с Transformer [21].

Данные алгоритмы выбраны исходя из их успешного применения в задачах регрессии и прогнозирования. Каждый алгоритм обучен на едином наборе данных с применением кросс-валидации, что позволило получить объективную оценку его эффективности [22]. Сравнение эффективности прогнозирования алгоритмов машинного обучения выполнено с помощью средней абсолютной ошибки (MAE) между фактическими и предсказанными значениями в соответствии с уравнением (3) [10]. Результаты сравнения показаны в табл. 2.

$$MAE = 1/n \sum_{i=1}^n |DD_{act} - DD_{prd}|, \quad (3)$$

где DD_{act} — фактическая глубина дефекта, DD_{prd} — прогнозируемая глубина дефекта, а n — количество наблюдений.

Из табл. 4 видно, что модель, включающая градиентный бустинг с Transformer, показала наилучший результат ($MAE = 0,3143$).

Модели, в которых используется извлеченная с помощью эмбедингов информация о технологическом режиме работы трубопроводов, как и ожидалось, показывают наилучшие результаты прогнозирования. Это подчеркивает значимость предварительной обработки данных и показывает жизнеспособность подхода извлечения значимой информации из временных рядов с использованием нейронных сетей.

Использование ансамблевых подходов (AutoML), хотя и продемонстрировало достойные результаты, все же уступает

Таблица 4. Сводные результаты экспериментов. Составлено авторами
Table 4. Summary of Experimental Results. Compiled by the authors

№ п/п	Алгоритм	Архитектура	MAE, Толщина стенки
1	Градиентный бустинг	CatBoost Regressor	0,79
2	AutoML	Ансамбль из слабых моделей классического ML	0,71
3	Градиентный бустинг с LSTM	CatBoost для предсказания, LSTM модель для эмбедингов	0,45
4	Классические подходы с LSTM, PCA и генерацией признаков	Ансамбль из слабых моделей классического ML для предсказания, LSTM модель для эмбедингов	0,39
5	Градиентный бустинг с LSTM, PCA и генерацией признаков	CatBoost для предсказания, LSTM модель для эмбедингов	0,35
6	Градиентный бустинг с Transformer	CatBoost для предсказания, Transformer модель для эмбедингов	0,31

специализированным архитектурам. Это указывает на то, что при решении данной задачи методы, использующие современные подходы машинного обучения, более предпочтительны.

РАЗРАБОТКА ИНСТРУМЕНТА ПРОГНОЗИРОВАНИЯ

Градиентный бустинг с Transformer послужил основой для разработки инструмента визуализации, анализа состояния трубопроводов и прогнозирования возможных отказов на основе ретроспективных данных.

Основные цели системы:

1. Обеспечение безопасности эксплуатации трубопроводов — система позволяет выявлять потенциальные риски на ранних стадиях, прогнозируя возможные отказы трубопроводов. Это даст возможность оперативного реагирования на угрозы и предотвращения отказов.
2. Минимизация затрат на обслуживание и ремонт — инструмент позволяет планировать техническое обслуживание с учетом реального состояния трубопровода, что предотвращает внеплановые остановки и снижает затраты на аварийный ремонт.
3. Повышение эффективности эксплуатации — применение алгоритма помогает оценивать динамику изменения состояния трубопровода, прогнозировать остаточный ресурс и обеспечивать надежную работу сети с минимальными перебоями.
4. Оптимизация процесса принятия решений — инструмент анализирует множество параметров, таких как коррозия, давление, температура и прочие эксплуатационные показатели, чтобы предложить оптимальные решения для продления срока службы инфраструктуры.
5. Автоматизация анализа данных — внедрение алгоритмов обработки данных позволяет оперативно анализировать

информацию о дефектах, изменениях эксплуатационных условий и прогнозируемых рисках, что упрощает работу специалистов и снижает человеческий фактор в процессе диагностики.

Для достижения этих целей требуется комплексная система, включающая в себя несколько ключевых компонентов, которые обеспечивают сбор, обработку, анализ и визуализацию данных, а также взаимодействие пользователей с инструментом прогнозирования.

Основные компоненты системы:

- Модуль сбора и обработки данных:
 - интеграция с базами данных отказов, диагностических проверок, эксплуатационных параметров;
 - импорт данных из внешних источников, включая файлы CSV и Excel;
- Модуль машинного обучения (ML):
 - обучение моделей прогнозирования на исторических данных;
 - прогнозирование остаточного ресурса на заданный период с учетом эксплуатационных параметров;
 - возможность симуляции различных сценариев эксплуатации;
- Модуль визуализации:
 - отображение состояния трубопроводов на интерактивной карте;
 - использование цветовых индикаторов риска для оценки состояния объектов;
 - визуализация аналитических данных в виде графиков и таблиц;
- Модуль аналитики и расчетов:
 - анализ дефектов и выявление критических зон трубопроводов;
 - расчет стоимости ремонтов на основе прогнозируемых дефектов;
 - формирование отчетности по состоянию трубопроводов;
- Модуль взаимодействия с пользователем:
 - настраиваемый интерфейс с возможностью поиска, фильтрации и сортировки данных;

– доступ к информации по трубопроводам в виде таблиц и картографических данных.

ВНЕДРЕНИЕ И ИСПОЛЬЗОВАНИЕ ИНСТРУМЕНТА В ОПЕРАЦИОННОЙ ДЕЯТЕЛЬНОСТИ

Для достижения максимальной эффективности созданного инструмента необходима правильная интеграция решения с существующими бизнес-процессами компании. Первым шагом в этой интеграции является анализ текущих процессов управления трубопроводами. Необходимо определить ключевые точки, в которых предиктивная аналитика может внести наибольший вклад, такие как этапы мониторинга состояния трубопроводов, планирование технического обслуживания, а также управление рисками. Отдельно стоит отметить важность встраивания аналитики непосредственно в процессы принятия решений, которое позволит оперативно реагировать на выявленные риски:

- Раннее предупреждение: использование результатов работы предиктивного алгоритма для заблаговременного уведомления сотрудников о возможных неисправностях, что позволит оперативно реагировать и минимизировать риски.
- Оптимизация графиков обслуживания: создание адаптивных графиков технического обслуживания на основе анализа вероятности отказов, что сокращает затраты на неэффективные профилактические работы и увеличивает время безотказной работы.
- Управление рисками и ресурсами: включение аналитики в процессы оценки рисков, что позволит минимизировать потенциальные убытки и более эффективно распределять ресурсы.

Кроме того, интеграция предиктивной аналитики в бизнес-процессы предоставляет несколько ключевых преимуществ:

- Снижение числа незапланированных простоев: прогнозирование остаточного ресурса позволяет избежать аварийных ситуаций, связанных с повреждениями трубопроводов.
- Уменьшение затрат на ремонты: своевременное выявление проблем позволяет уменьшить расходы на капитальный ремонт и необоснованные замены оборудования.
- Повышение безопасности: прогнозирование отказов способствует снижению рисков аварий, что важно для охраны труда и защиты окружающей среды.
- Повышение эффективности работы персонала: системы предиктивной аналитики позволяют сотрудникам сосредоточиться на приоритетных задачах и улучшить качество работы.

Оценка эффективности предиктивной аналитики отказов трубопроводов и ее сравнение с традиционными методами технического обслуживания имеет большое значение для понимания преимуществ и ограничений данной технологии. Традиционные подходы поддержания работоспособности трубопроводных систем включают в себя:

- Плановое обслуживание: регулярные проверки и технические осмотры на основе календарных интервалов, независимо от реального состояния трубопроводов.
- Реактивное обслуживание: методика основана на исправлении проблем непосредственно после их возникновения. Включает действия после того, как произошел отказ, и часто связано с высокой стоимостью из-за аварийных ремонтов и простоев.

Таблица 5. Сравнение традиционных методов с предиктивной аналитикой. Составлено авторами
Table 5. Comparison of Traditional Methods with Predictive Analytics. Compiled by the authors

Критерий	Традиционные методы	Предиктивная аналитика
Затраты на техническое обслуживание	Часто чрезмерные из-за плановых осмотров и реактивных ремонтов	Снижение затрат за счет уменьшения числа ненужных работ и раннего выявления неисправностей
Надежность системы	Зависит от периодичности проверок и их качества. Часто возникают неожиданные поломки	Высокая надежность благодаря анализу данных и точным прогнозам отказов
Продолжительность простоя	Длительные простои из-за аварийных ремонтов	Минимизация простоев за счет профилактики отказов
Эффективность ресурсов	Неоптимальное использование рабочих часов и оборудования	Оптимизация использования человеческих и технических ресурсов
Гибкость в принятии решений	Ограничена из-за фиксированных интервалов обслуживания и недостатка информации	Высокая гибкость и адаптивность благодаря анализу в реальном времени
Стоимость обслуживания	Потенциально высокая из-за частых и необоснованных проверок или затрат на аварийные ремонты	Снижение затрат благодаря оптимизированному графику обслуживания и предотвращению аварий

На сегодняшний день существует ряд ограничений, не позволяющих в полной мере охватить нефтесборные сети традиционными методами оценки.

- Ограничения технологического характера:
 - трубопроводы диаметрами менее 159 мм;
 - трубопроводы с внутренним покрытием;

- трубопроводы системы ППД;
- неметаллические трубопроводы;
- Экономические ограничения:
 - стоимость проведения работ;
 - стоимость монтажа камер пуска-приема.

Таким образом, традиционные методы могут быть неэффективными с точки зрения





Рис. 3 Операционализация инструмента предиктивной аналитики. Составлено авторами
Fig. 3 Operationalization of the Predictive Analytics Tool. Compiled by the authors



затрат и времени, поскольку не обеспечивают своевременное выявление проблем до их возникновения, а также часто приводят к излишним затратам на профилактическое обслуживание.

Предиктивная аналитика отказов трубопроводов, в отличие от традиционных методов, основывается на использовании данных о текущем состоянии трубопроводной системы и анализе возможных отказов на основе статистических моделей и алгоритмов машинного обучения.

Подробное сравнение традиционных методов и предиктивной аналитики по наиболее ключевым показателям приведено в табл. 5.

ВЫВОДЫ

Итогом проделанной работы является инструмент предиктивной аналитики отказов нефтепромысловых трубопроводов, в ходе реализации которого решена задача прогнозирования появления и развития

коррозионных дефектов. Операционализация инструмента способствует повышению надежности трубопроводного транспорта, снижению эксплуатационных затрат и оптимизации технического обслуживания.

На текущий момент идет активная стадия внедрения предиктивной аналитики отказов трубопроводов в схему бизнес-процесса принятия решений по повышению целостности и надежности нефтесборных сетей. Результаты прогноза использовались при формировании графиков диагностики трубопроводов на 2025 год (рис. 3).

Кроме того, на основании полученных результатов оценена динамика изменения состояния нефтесборных сетей, а также разработаны мероприятия по обеспечению их бесперебойной работы (рис. 4).

На текущий момент инструментом предиктивной аналитики охвачены все нефтесборные сети и напорные нефтепроводы. Дальнейшее развитие и расширение функционала системы планируется с учетом охвата водоводов и газопроводов.

Список литературы

1. М-01.06.06-04 Методические указания по организации и исполнению программ диагностики промысловых трубопроводов Компании. Москва: ОАО «Газпром нефть». 2017; 160.
2. Pipeline Operators Forum (POF) «Specifications and requirements for in-line inspection of pipelines», 2016.
3. РД-23.040.00-КТН-011-16 «Определение прочности и долговечности труб и сварных соединений с дефектами». ОАО «АК «Транснефть», 2018.
4. API 570 Piping Inspection Code Inspection, Repair, Alteration, and Rerating of In-service Piping Systems, 2003.
5. Методика определения опасности повреждений стенки труб магистральных нефтепроводов по данным обследования внутритрунными дефектоскопами / Под ред. АК «Транснефть». М.: Транспресс, 1997; 32.
6. Rafael Amaya-Gomez. Modeling of pipeline corrosion degradation mechanism with a Levy Process based on ILI (In-Line) inspections. International Journal of Pressure Vessels and Piping. Elsevier. 2019; 21.
7. Caley F, Velazquez J.C., Valor A., Hallen J.M. Probability distribution of pitting corrosion depth and rate in underground pipelines: A Monte Carlo study. Corrosion Science. 2009;51:1925–1934.
8. DNV-RP-F101 Recommended practice. Corroded pipelines. Norway: Det Norske Veritas, 2017; 123.
9. Vanaei H.R., Eslami A., Egbewande A. A review on pipeline corrosion, in-line inspection (ILI), and corrosion growth rate models. International Journal of Pressure Vessels and Piping. 2017;149:44–55.
10. СТО Газпром 2-2.3-361-2009 Руководство по оценке и прогнозу коррозионного состояния линейной части магистральных газопроводов. Москва: ОАО «Газпром». 2010.
11. Полуян Л.В. Марковская модель роста коррозионных дефектов и ее применение для управления целостностью трубопроводов / Л.В. Полуян. Проблемы машиностроения и надежности машин. 2009;6:105–111.
12. ASME B31.8-2003 standard. Gas transmission and distribution piping systems. Revision of ASME 831.8-1999. NY: ASME, 2004; 190.
13. OCT 153-39.4-010-2002 Методика определения остаточного ресурса нефтегазопромысловых трубопроводов и трубопроводов головных сооружений. Москва, 2002.
14. Гончаров А.А. Коррозионное состояние и долговечность оборудования и трубопроводов сероводородсодержащих нефтегазовых месторождений: дис. ... канд. техн. наук. Москва. 2000; 210.
15. Ahammed M. Probabilistic estimation of remaining life of a pipeline in the presence of active corrosion defects. International Journal of Pressure Vessels and Piping. 1998;75:321–329.
16. Polouian L.V. Holistic approach to acquisition and statistical analysis of ILI results / L.V. Polouian, S.A. Timashev. Proceedings of the Biennial International Pipeline Conference, IPC: 2006 6th International Pipeline Conference, IPC 2006, 25–29 сентября 2006 года / sponsors: ASME, International Petroleum Technology Institute, IPIT. Calgary, AB, 2007; 439–446.
17. Guanzhi Li, Aining Zhang, Qizhi Zhang, Di Wu, Choujun Zhan. Pearson correlation coefficient-based performance enhancement of broad learning system for stock price prediction. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022.
18. Jerome H. Friedman. Greedy function approximation: A gradient boosting machine. Ann. Statist, 2001.
19. Le T.T., Weixuan Fu, Moore J.H. Scaling tree-based automated machine learning to biomedical big data with a feature set selector. Bioinformatics. January 2020;36(1):250–256. <https://doi.org/10.1093/bioinformatics/btz470>
20. Sepp Hochreiter, Jürgen Schmidhuber. Long Short-Term Memory, 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>
21. Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin. Advances in Neural Information Processing Systems, 2017.
22. Stone M. Cross-Validatory Choice and Assessment of Statistical Predictions. Journal of the Royal Statistical Society: Series B (Methodological). January 1974;36(2):111–133. <https://doi.org/10.1111/j.2517-6161.1974.tb00994.x>

References

1. M-01.06.06-04 Guidelines for the organization and implementation of diagnostic programs for the Company's field pipelines. Moscow: Gazprom Neft. 2017; 160.

2. Pipeline Operators Forum (ПОТ) «Specifications and requirements for in-line inspection of pipelines», 2016.
3. *GD-23.040.00-KTH-011-16 Determination of the strength and durability of pipes and welded joints with defects*. Transneft, 2018.
4. API 570 Piping Inspection Code Inspection, Repair, Alteration, and Rerating of In-service Piping Systems, 2003.
5. *Methodology for determining the risk of damage to the wall of pipes of main oil pipelines based on inspection data from in-line flow detectors* / Ed. by Transneft. Moscow: Transpress, 1997; 32.
6. Rafael Amaya-Gomez Modeling of pipeline corrosion degradation mechanism with a Levy Process based on ILI (In-Line) inspections. *International Journal of Pressure Vessels and Piping*. Elsevier. 2019; 21.
7. Caley F., Velazquez J.C., Valor A., Hallen J.M. Probability distribution of pitting corrosion depth and rate in underground pipelines: A Monte Carlo study. *Corrosion Science*. 2009;51:1925–1934.
8. DNV-RP-F101 Recommended practice. *Corroded pipelines*. Norway: Det Norske Veritas, 2017; 123.
9. Vanaei H.R., Eslami A., Egbewande A. A review on pipeline corrosion, in-line inspection (ILI), and corrosion growth rate models. *International Journal of Pressure Vessels and Piping*. 2017;149:44–55.
10. *OS Gazprom 2-2.3-361-2009 Guidelines for assessment and forecast of corrosion condition of linear section of main gas pipelines*. Moscow, Gazprom. 2010.
11. Poluyan L.V. Markov model of corrosion defect growth and its application to pipeline integrity management / L.V. Poluyan. *Problems of mechanical engineering and reliability of machines*. 2009;6:105–111.
12. ASME B31.8-2003 standard. *Gas transmission and distribution piping systems*. Revision of ASME 831.8-1999. NY: ASME, 2004; 190.
13. *IS 153-39.4-010-2002 Methodology for determining the residual life of oil and gas field pipelines and pipelines of head structures*. Moscow, 2002.
14. Goncharov A.A., *Corrosion condition and service life of equipment and pipelines of hydrogen sulfide-containing oil and gas fields*: dissertation for the degree of candidate of technical sciences, Moscow, 2000; 210.
15. Ahammed M. Probabilistic estimation of remaining life of a pipeline in the presence of active corrosion defects. *International Journal of Pressure Vessels and Piping*. 1998;75:321–329.
16. Polouian L.V. *Holistic approach to acquisition and statistical analysis of ILI results* / L.V. Polouian, S.A. Timashev. Proceedings of the Biennial International Pipeline Conference, IPC: 2006 6th International Pipeline Conference, IPC 2006, 25–29 Sept. 2006 / sponsors: ASME, International Petroleum Technology Institute, IPIT. Calgary, AB, 2007; 439–446.
17. Guanzhi Li, Aining Zhang, Qizhi Zhang, Di Wu, Choujun Zhan. *Pearson correlation coefficient-based performance enhancement of broad learning system for stock price prediction*. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022.
18. Jerome H. Friedman. *Greedy function approximation: A gradient boosting machine*. Ann. Statist, 2001.
19. Le T.T., Weixuan Fu, Moore J.H. Scaling tree-based automated machine learning to biomedical big data with a feature set selector. *Bioinformatics*. January 2020;36(1):250–256. <https://doi.org/10.1093/bioinformatics/btz470>
20. Sepp Hochreiter, Jürgen Schmidhuber. Long Short-Term Memory, 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>
21. Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, Illia Polosukhin. *Advances in Neural Information Processing Systems*, 2017.
22. Stone M. Cross-Validatory Choice and Assessment of Statistical Predictions. *Journal of the Royal Statistical Society: Series B (Methodological)*. January 1974;36(2):111–133. <https://doi.org/10.1111/j.2517-6161.1974.tb00994.x>

ВКЛАД АВТОРОВ / AUTHOR CONTRIBUTIONS

А.Ф. Садыков — осуществлял общее руководство проектом, координировал работу команды и обеспечивая взаимодействие между различными подразделениями для успешной реализации поставленных задач, окончательно утвердил публикуемую версию статьи.

Б.И. Мухаметзянов — внёс значительный вклад в разработку концепции и стратегического подхода к созданию инструмента предиктивной аналитики, курировал процесс моделирования и анализа данных.

М.В. Черняк — разработал концепцию статьи, подготовил текст статьи, провёл критический анализ методологии и предложенных алгоритмов, а также внёс ценные рекомендации по совершенствованию модели предсказания.

Д.В. Батрашкин — оказал экспертное сопровождение процесса разработки инструмента, производил контроль за внедрением, утвердил публикуемую версию статьи.

Р.А. Абдуллаев — оказал методологическое сопровождение и внедрение инструмента, производил рецензирование статьи.

Р.Ф. Гимазетдинов — принял активное участие в подготовке текста статьи, проводил экспертное сопровождение проекта, участвовал при разборе и оценке качества прогноза, полученного в инструменте предиктивной аналитики.

Azamat F. Sadykov — carried out the overall management of the project, coordinated the team's work and ensured interaction between various departments for the successful implementation of the tasks, approved the final version of the article.

Bulat I. Mukhametzyanov — made a significant contribution to the development of the concept and strategic approach to the creation of a predictive analytics tool, supervised the process of modeling and data analysis, approved the final version of the article.

Mikhail V. Chernyak — developed the article concept, prepared a text of the article, conducted a critical analysis of the methodology and proposed algorithms, and also made valuable recommendations for improving the prediction model.

Dmitry V. Batrashkin — provided expert support for the development process of the tool, monitored its implementation, and approved the published version of the article.

Rafael A. Abdullaev — provided methodological support and implementation of the tool, and conducted a review of the article.

Ramis F. Gimazetdinov — actively participated in preparing the text of the article, provided expert support for the project, and was involved in analyzing and evaluating the quality of the forecast obtained in the predictive analytics tool.

У.М. Саттаров — контролировал качество и сроки выполнения работ, принял участие в редактировании разделов статьи. Принимал участие по сбору и верификации исходных данных для реализации проекта.

Ural M. Sattarov — monitored the quality and deadlines for the work, participated in editing sections of the article, and took part in collecting and verifying initial data for the project implementation.

СВЕДЕНИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Азамат Фиргатович Садыков — директор департамента по продуктовой разработке, ООО «Недра»

Azamat F. Sadykov — Director of the Product Development Department, Nedra LLC

Булат Ильгизович Мухаметзянов — руководитель группы по продуктам предиктивного анализа и энергоэффективности, ООО «Недра»

Bulat I. Mukhametzyanov — Head of the Predictive Analysis and Energy Efficiency Products Group, Nedra LLC

Михаил Вячеславович Черняк — эксперт группы по продуктам предиктивного анализа и энергоэффективности, ООО «Недра»

Mikhail V. Chernyak — Expert of the Predictive Analysis and Energy Efficiency Products Group, Nedra LLC

Дмитрий Валерьевич Батрашкин — операционный директор, Группа компаний «Газпром нефть»

Dmitry V. Batrashkin — Chief operating officer, Gazprom нефть company group

Рафаэль Азерович Абдуллаев* — руководитель проектов, Группа компаний «Газпром нефть» 628011, Ханты-Мансийский автономный округ — Югра, г. Ханты-Мансийск, ул. Ленина, д. 56. e-mail: Abdullaev.RA@hantos.gazprom-neft.ru

Rafael A. Abdullaev* — Project Manager, Gazprom нефть company group 56, Lenina St., Khanty-Mansiysk, Khanty-Mansiysk Autonomous Okrug — Yugra, 628011, Russia. e-mail: Abdullaev.RA@hantos.gazprom-neft.ru

Рамис Фанисович Гимазетдинов — руководитель направления по управлению потенциалом инфраструктуры, Группа компаний «Газпром нефть»

Ramis F. Gimazetdinov — Head of Infrastructure Potential Management section, Gazprom нефть company group

Урал Миратович Саттаров — руководитель направления по моделированию инфраструктуры, Группа компаний «Газпром нефть»

Ural M. Sattarov — Head of Infrastructure Modeling section, Gazprom нефть company group

* Автор, ответственный за переписку / Corresponding author