

УДК 004.89

DOI: [10.26102/2310-6018/2024.44.1.017](https://doi.org/10.26102/2310-6018/2024.44.1.017)

Обзор нейросетевых моделей для решения задач прогнозирования аварийных ситуаций и обеспечения безопасности функционирования нефтегазовых скважин

А.Е. Сулавко¹✉, В.И. Васильев², С.А. Клиновенко¹, П.С. Ложников¹,
Г.А. Сувырин¹, М.Б. Гузаиров²

¹Омский государственный технический университет, Омск, Российская Федерация

²Уфимский университет науки и технологий, Уфа, Российская Федерация

Резюме. Проведено аналитическое исследование проблемы предупреждения аварийных ситуаций и предиктивной диагностики оборудования при добыче углеводородов на нефтегазовых месторождениях, а также способов решения данной проблемы путем использования искусственного интеллекта, основанного на глубоких нейронных сетях. Одним из ключевых факторов, сдерживающих развитие систем предиктивной диагностики оборудования, является недостаток данных, описывающих предаварийные ситуации, которые необходимы для качественного обучения нейросетевых моделей. Приводится обзор публикаций и исследований последних лет по тематике анализа телеметрических данных и распознавания аварийных ситуаций. Рассматриваются нейросетевые модели, которые могут быть использованы для прогнозирования выхода из строя насосно-компрессорного оборудования и других агрегатов. Изучены случаи применения нейросетевых моделей, специально обученных для решения данной задачи, а также нейросетевые модели, используемые в иных задачах, но анализирующие схожие структуры данных. Поднимается вопрос переноса обучения, чтобы адаптировать нейросетевые модели, изначально разработанные и обученные для других областей, к использованию в рассматриваемой области, в целях уменьшения объема выборки при обучении промышленного искусственного интеллекта. Проведено сравнение достигнутых результатов, обозначены преимущества и недостатки существующих технических решений.

Ключевые слова: искусственные нейронные сети, предиктивная диагностика, машинное обучение, временные ряды, телеметрия, техническое обслуживание, наборы данных.

Благодарности: работа выполнена ОмГТУ в рамках государственного задания Минобрнауки России на 2023–2025 годы (FSGF-2023-0004).

Для цитирования: Сулавко А.Е., Васильев В.И., Клиновенко С.А., Сувырин Г.А., Ложников П.С., Гузаиров М.Б. Обзор нейросетевых моделей для решения задач прогнозирования аварийных ситуаций и обеспечения безопасности функционирования нефтегазовых скважин. *Моделирование, оптимизация и информационные технологии*. 2024;12(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1472> DOI: 10.26102/2310-6018/2024.44.1.017

Review of neural network models for solving the problems of predicting emergency situations and ensuring the safe operation of oil and gas wells

A.E. Sulavko¹✉, V.I. Vasiliev², S.A. Klinovenko¹, G.A. Suvyrin¹, P.S. Lozhnikov¹,
M.B. Guzairov²

¹Omsk State Technical University, Omsk, the Russian Federation

²Ufa University of Science and Technology, Ufa, the Russian Federation

Abstract. An analytical study was carried out on the problem of preventing emergency situations and predictive diagnostics of equipment during hydrocarbon production in oil and gas fields as well as the ways to solve this problem by means of artificial intelligence based on deep neural networks. One of the key factors hindering the development of predictive equipment diagnostic systems is the lack of data describing pre-emergency situations, which is necessary for high-quality training of neural network models. An analysis of recent publications and research on the subject of telemetry data analysis and emergency recognition is provided. Neural network models are considered that can be used to predict the failure of pumping and compressor equipment and other units. Cases of the use of neural network models specially trained to solve this problem, as well as neural network models used in other tasks but analyzing similar data structures, were studied. The issue of transfer learning is raised to adapt neural network models originally developed and trained for other areas to use in the area under consideration in order to reduce the sample size when training industrial artificial intelligence. A comparison of the achieved results was carried out, and the advantages and disadvantages of existing technical solutions were identified.

Keywords: artificial neural networks, predictive diagnostics, machine learning, time series, telemetry, maintenance, data sets.

Acknowledgements: the research was carried out as part of the state assignment of Ministry of Science and Higher Education of the Russian Federation for years 2023–2025 (subject No. FSGF-2023-0004).

For citation: Sulavko A.E., Vasiliev V.I., Guzairov M.B., Klinovenko S.A., Suvyrin G.A., Lozhnikov P.S. Review of neural network models for solving the problems of predicting emergency situations and ensuring the safe operation of oil and gas wells. *Modeling, Optimization and Information Technology*. 2024;12(1). URL: <https://moitvvt.ru/ru/journal/pdf?id=1472> DOI: 10.26102/2310-6018/2024.44.1.017 (In Russ.).

Введение

Использование современных систем сбора информации и технологий искусственного интеллекта (ИИ) дает возможность качественно изменить бизнес-процессы организаций в нефтегазовой отрасли [1], что позволит снизить финансовые затраты на разведку и разработку месторождений. Однако на текущий момент нефтегазовая отрасль в России цифровизована в малой степени.

Повышение нефтеотдачи, снижение количества отказов оборудования и затрат на его эксплуатацию позволяют уменьшить капитальные и операционные расходы [2]. Основная доля убытков на этапе добычи приходится на незапланированные простои оборудования, убытки от этого могут достигать сотни миллионов рублей в день [3]. По этой причине крайне важно внедрять системы предиктивной диагностики нефтегазовых агрегатов.

В настоящее время для автоматизации процессов распознавания образов, управления, прогнозирования, создания экспертных систем применяют искусственные нейронные сети (ИНС). Нейронные сети с их способностью извлекать смысл из сложных или неточных данных могут быть использованы для выявления тенденций, которые слишком сложны, чтобы их можно было предсказать или зафиксировать с помощью классических методов анализа сигналов [4]. Использование ИНС позволяет увеличить точность прогнозов и дает возможность разрабатывать надежные промышленные модели ИИ.

Цель настоящей работы – провести аналитический обзор публикаций в области прогнозирования аварийных ситуаций и обеспечения безопасности при эксплуатации нефтяных скважин с помощью ИНС. В статье обобщаются достигнутые результаты в данной области, существующие проблемы и методы их решения.

Границы исследования

Рассмотрены публикации, размещенные в открытых электронных библиотеках, таких как Springer, Elibrary. Выполнен анализ научных статей, индексируемых в системах цитирования РИНЦ, Scopus или Web of Science. Поиск проводился по таким ключевым словам, как risk assessment (оценка рисков), machine learning (машинное обучение), neural network (нейронная сеть), fault diagnosis (диагностика неисправностей), sensor fault detection (обнаружение неисправностей датчиков), telemetry analysis (анализ телеметрических данных), neural network models (нейросетевые модели), data analysis (анализ данных), classification (классификация), telemetric information (телеметрическая информация), fully connected neural networks / layers (полносвязные нейронные сети / слои), one-dimensional convolutional neural networks / layers (одномерные сверточные нейронные сети / слои), recurrent neural networks / layers (рекуррентные нейронные сети / слои), offshore platform (морская платформа), remaining useful life prediction (прогноз оставшегося срока полезного использования), Structural Integrity Management (управление структурной целостностью), Feed-Forward Neural Networks (нейронные сети прямого распространения), electric centrifugal pump (электрический центробежный насос), oil and gas industry (нефтегазовая отрасль), mineral extraction (добыча ископаемых), field development (разработка месторождений), drilling optimization (оптимизация бурения), predictive maintenance of units (предиктивное обслуживание агрегатов), pumping and compressor equipment (насосно-компрессорное оборудование). Также использовались сочетания терминов из нефтегазовой отрасли и области машинного обучения. Изучены модели и алгоритмы ИИ, реализованные на популярных языках программирования (Python, C# и т. д.) и размещенные на Интернет-площадках Kaggle, Towardsdatascience и Medium в виде исходных текстов программ.

Исследование было посвящено следующим основным вопросам:

1. Условия экспериментов по сбору данных, характеристики наборов данных.
2. Особенности использования моделей, методов и алгоритмов машинного обучения.
3. Использованные метрики, количественные и качественные показатели результатов.

Из результатов обзора относящихся к теме исследования публикаций исключены статьи и материалы конференций, не соответствующие критериям научной обоснованности и воспроизводимости. Было выбрано 22 работы, удовлетворяющие заданные критерии и выполненные в период с 2017 по 2023 гг. Публикации можно разделить на 2 основные категории:

1. Анализ телеметрических данных для диагностики насосно-компрессорного оборудования (10 публикаций).
2. Анализ телеметрических данных в смежных областях (12 публикаций).

Наборы данных телеметрии

Эксплуатация нефтяных скважин сопряжена с применением различного вида датчиков и систем, основанных на гидравлических, пневматических и механических принципах работы. Данные датчики и системы размещаются как в самой скважине, так и рядом с ней. Возможно также размещение частично или полностью под водой.

Одной из самых больших проблем при использовании ИНС является подготовка и обработка тренировочных данных. В результате анализа открытых источников для сравнения было выбрано 3 набора данных, собранных по данным датчиков нефтегазового оборудования.

Конфронтативные данные наборов приведены в Таблице 1.

Таблица 1 – Сравнительная таблица наборов данных из открытых источников
Table 1 – Comparison table of open source datasets

Название набора	Описание	Характеристики
Volve Data Village ¹	Реальные данные бурения и эксплуатации 15 нефтяных скважин. Ставились задачи прогнозирования объемов добычи нефти, разработки месторождений	18 параметров (признаков), 15635 образов (измерений). Размерность: 18x15635
Predictive Equipment Failures ²	Реальные данные эксплуатации нефтяных скважин. Ставилась задача классификации аварий	60000 образов (измерений), каждый из которых содержит показатели 107 датчиков (170 значений совокупно). 2-го класса: внутрискважинные и внескважинные аварии. Размерность: 170x60000
3W Dataset ³	Реальные и смоделированные (с помощью симулятора OLGA) данные датчиков нефтегазодобывающего оборудования. Ставилась задача прогнозирования и классификации аварий на нефтяных морских скважинах. Длительность данных составляет от 5 минут до 72 часов	1984 образов (серий по несколько тысяч измерений от 1080 до 345602), каждый представлен данными 8 датчиков в виде временных рядов с частотой дискретизации 1 Гц. 3-го класса: нормальная работа, предаварийная и аварийная ситуация. Размерность: 50913215x8

Первые два набора данных затруднительно использовать для прогнозирования аварийных ситуаций (эти наборы скорее ориентированы на задачу классификации образов). В наборе Volve Data Village¹ очень малое количество признаков; большая часть данных относится к физическим свойствам нефтедобывающих скважин или показателям добычи нефти, а не к данным оборудования и датчиков. Также набор имеет большое количество пропусков и малый объем. Набор данных Predictive Equipment Failures² содержит недостаточно сбалансированные классы (только 1,7 % аварийных ситуаций относятся к отказам оборудования внутри скважины), большинство измерений имеют пропуски (более 66 % показаний имеют более 5 % пропусков), размер набора также недостаточен. Хотя количество измерений насчитывает 60000, их сложно разбить на большое количество непересекающихся интервалов для проведения серии независимых опытов по прогнозированию.

Набор 3W Dataset³ самый объемный, он состоит из реальных и смоделированных данных, каждый экземпляр набора содержит метки времени, метки наблюдений (нормальная, предаварийная и аварийная ситуация) и данные восьми датчиков. Набор данных может использоваться для решения задачи прогнозирования аварий на нефтедобывающем оборудовании, хотя существенная часть данных также повреждена (классы сбалансированы не лучшим образом, данные имеют пропуски).

¹ Volve Data Village. Equinor Open Data [Internet]. data.equinor.com. [cited 2023 Oct 27]. Available from: <https://data.equinor.com/dataset/Volve>

² Predictive Equipment Failures [Internet]. kaggle.com. [cited 2023 Oct 27]. Available from: <https://www.kaggle.com/competitions/equipfailstest/data>

³ 3W Dataset – Undesirable events in oil wells [Internet]. www.kaggle.com. [cited 2023 Oct 27]. Available from: <https://www.kaggle.com/datasets/afrniomelo/3w-dataset>

Сравнение результатов по предиктивной диагностике насосно-компрессорного оборудования

Добыча нефти в текущий момент производится путем использования нефтяных скважин, шахт и карьеров. Механизированная добыча нефти выполняется с помощью лифтов (газлифтов, плунжерным лифтов) или насосов (штанговых, роторных, гидравлических, электрических, пневматических, штанговых).

Исследование [5] полностью посвящено улучшению качества диагностики газоперекачивающих агрегатов. В публикации создан новый адаптивный метод SR-GAN для анализа значений вибрации и эффективного обнаружения признаков аварии. В основе разработанного метода лежит адаптивный подход стохастического резонанса (SR) и генеративно-сопоставительная нейронная сеть (GAN). Преимущество данного подхода состоит в повышении точности (accuracy) диагностики на 2,1 % и повышении отношения сигнала к шуму на 2,25 дБ. Метод имеет большую точность классификации при использовании малых выборок.

В [6] рассматривалась задача расчета вероятности отказа электроцентробежного насоса. Для решения проблемы автор опирался на ИНС. Для обучения модели была проанализирована статистика изменения параметров 40 тысяч скважин, оборудованных УЭЦН (установка электроприводного центробежного насоса), на которых произошли отказы установок. Обучающая выборка составляла 80 %, тестовая – 20 %. Точность предсказания отказа установки составила 94 %.

В научной работе [7] проведено исследование проблемы нахождения аномалий устройств на нефтегазодобывающих платформах. Автор использует ИНС с 1 скрытым слоем, состоящим из 10 нейронов с сигмоидальной активацией. Также модель обучалась с использованием алгоритма Левенберга-Марквардта и рассчитана на один датчик. Заявлено, что регрессионная модель может обнаруживать аномалии, моделируя сигнал устройства на основе показаний других устройств. Обучающая выборка составляла 70 % от набора данных.

Исследование [8] посвящено прогнозированию показателей скважин, для добычи нефти с помощью рекуррентной нейронной сети с долгой краткосрочной памятью (LSTM) на примере месторождения с системой заводнения. Алгоритм прогнозирования основан на расчете технологических режимов работы добывающих скважин за определенное количество месяцев. Каждый последующий прогноз рассчитывается уже с учетом предсказанных на предыдущем шаге значений. Алгоритм выполняется до тех пор, пока не будет достигнуто окончание заданного периода прогнозирования.

В [9] рассматривается вопрос оценки факторов риска аварийных ситуаций при эксплуатации насосно-компрессорного оборудования. В работе использовались данные 67 скважин, в основе лежит процедура последовательного построения алгоритмов машинного обучения, когда каждый последующий алгоритм стремится компенсировать недостатки предыдущих. Обучающая выборка составляла 80 % от общего числа данных, 20 % данных составляла тестовая выборка. Количество эпох обучения 400, скрытый слой имеет 21 нейрон, F-мера составила 95,1 %.

Научная работа [10] посвящена диагностике неисправности установок для перекачки природного газа, использовались акустические и вибрационные данные, отобранные в разных режимах работы установки ГТК-25-И. Частота дискретизации составила 44,1 кГц. Применялась ИНС с плотной прямой связью (FNN), использующая комбинацию сигналов акустической эмиссии и вибрации в качестве входных данных модели. Модель обучена алгоритмом обратного распространения ошибки. Пакетная нормализация применяется между всеми слоями. Общий размер набора данных составляет 36878 фрагментов сигнала: 10339 фрагментов для "идеального" состояния,

25033 фрагмента для “нормального” состояния и 1506 фрагментов для “неисправного” состояния. Весь набор данных был разделен на обучающие, валидационные и тестовые выборки с использованием следующего соотношения 70 % : 10 % : 20 %. Точность предсказания модели составила 98 %.

В работе [11] на основе алгоритма глубокого обучения и плотно связанной сверточной нейронной сети DenseNet (Densely Connected Convolutional Network) создается модель диагностики неисправностей для насосной установки с помощью метода переноса обучения. Модель используется для классификации и тестирования различных рабочих условий, таких как отложение парафина, утечка насоса, недостаточная подача жидкости и утечка насоса в нефтяных скважинах. Модель DenseNet представляет собой модель классификации изображений с характеристиками повторного использования параметров. Обучение проводилось в 100 эпох, объем обучающей выборки составил 80 %. Точность предсказания составила 95 %, набор данных состоял из 3502 групп реальных данных.

В [12] целью исследования было прогнозирование отказов оборудования нефтяных скважин на основе нейронных сетей с прямой связью. Набор данных состоял из 172 функций (показания 107 датчиков, 100 из которых имеют одиночные показания, а остальные 7 формируют 10 временных рядов каждый, также имеются метки классов и порядковый номер). Набор данных был разделен на обучающую (80 %) и тестовую (20 %) выборки. Полученная модель основывалась на применении нейронной сети с прямой связью, обучаемой с помощью алгоритма стохастического градиентного спуска. Обучение модели происходило на протяжении 50 эпох, итоговая точность модели составила 97 %, а F-мера – 52 %.

В работе [13] предложен новый подход, основанный на реляционном и репрезентативном машинном обучении, который сравнивается с предсказанием на основе IL-Miner, а также с рекуррентными нейронными сетями LSTM. Авторы использовали набор данных 3W³ с 8 классами неисправностей, описываемых временными рядами показателей датчиков. Авторы преобразовали временные ряды в динамический граф знаний и предложили алгоритмы изучения вероятностных паттернов конечного автомата и стоимостной модели для прогнозирования критических событий, а также для выбора оптимальных параметров модели.

Магистерская диссертация [14] направлена на решение проблемы автоматического обнаружения и классификации аварийных событий при практической эксплуатации нефтяных и газовых скважин. Апробировано множество подходов к поиску информативных признаков, включая использование генетического алгоритма (GA), а также множество классификаторов: SVM, KNN, многослойный перцептрон (MLP), RF, адаптивный бустинг (ADA), машина экстремального обучения (ELM). Точность классификации составила 91,2 %.

Конфронтативные данные исследований приведены в Таблице 2.

Таблица 2 – Сопоставительные данные по нейросетевым моделям для предиктивной диагностики насосно-компрессорного оборудования

Table 2 – Comparative data on neural network models for predictive diagnostics of pumping and compressor equipment

Архитектура ИНС	Данные	Результат	Источник литературы
SR-GAN (параметры не указаны)	Вибрационные сигналы при скорости компрессора 4244 об/мин и частоте вращения вала 70,73 Гц	Точность (Accuracy) выше на 2,1 %, меньше обучающих примеров	[5]
ИНС (параметры не указаны)	Данные 40 тысяч скважин, оборудованных установками электроцентробежного насоса, на которых произошли отказы	Точность (Accuracy) 94 %	[6]
ИНС (1 скрытый слой, состоящий из 10 нейронов с сигмоидальной активацией)	Данные 46 датчиков многоступенчатого центробежного компрессора фиксировались с 10-минутным интервалом в 6 месяцев	Точность (Accuracy) 92 %	[7]
LSTM (2 скрытых слоя 256 и 100 нейронов соответственно)	Обучающая выборка учитывала 16 режимов работы скважин за период 7,5 лет	Точность (Accuracy) 98,9 %	[8]
ИНС (персептрон, скрытый слой из 21 нейрона)	Реальные данные 67 скважин, набор данных из 5315 строк	F-мера (F-score) 95,1%	[9]
FNN (входной слой из 3 нейронов 2 скрытых слоя с активацией ReLU из 128 и 256 нейронов, выходной слой с активацией SoftMax)	36878 группы реальных данных газоперекачивающего агрегата ГТК-25И, частота выборки составила 44,1 кГц, разрешение 16 бит	Точность (Accuracy) 98 %	[10]
DenseNet (блок из 4 слоев с BN-ReLU-Conv и 1 переходный слой)	3502 группы данных, 37 типов неисправности на нефтегазовом оборудовании нефтяного месторождения Дацин, КНР	Точность (Accuracy) 95 %	[11]
FNN (6 скрытых слоев по 32 нейрона)	Показания 107 датчиков, расположенных на малодебитных нефтяных скважинах ConocoPhillips, США ²	Точность (Accuracy) 97 %, F-мера (F-score) 52 %	[12]
LSTM (1 скрытый слой с 500 нейронами)	$3W^3$	Полнота (Recall) 69 %, Точность (Precision) 80 %	[13]
MLP (7 скрытый слоев: 64, 100, 256, 512, 100, 200, 500 нейронов соответственно) и другие модели	$3W^3$	Точность (Accuracy) 91,2 %	[14]

Рассмотрим работу [15], в которой не применялась ИНС, однако использован открытый набор данных $3W$, что позволяет осуществить корректное сравнение

результатов исследований с работами [13, 14]. Для определения неисправностей использовался классификатор «случайный лес», который настраивался отдельно на каждый тип неисправности. Три эксперимента проведены для оценки производительности системы в различных сценариях классификации. Достигнута точность 94 % при времени обнаружения в среднем 12 % переходного периода, предшествующего состоянию неисправности.

Как можно видеть (Таблица 2), достигнутые результаты в целом можно назвать удовлетворительными (в отдельных случаях [8, 10] – высокими). Однако в реальной практике, как правило, такие показатели не удается продемонстрировать (обученные модели при работе в реальных условиях все-таки дают больший процент ошибок). В представленных исследованиях преимущественно применялись закрытые наборы данных с обучающей выборкой достаточного объема. Эти данные являются специфичными для каждой диагностической задачи в отдельности, а наборы данных для исследований, как правило, собирались годами (что повлекло огромные затраты). Отказы случаются довольно редко, но приносят при этом огромные убытки. Нефтегазовые компании обычно не публикуют эти данные в открытых источниках.

Сравнение результатов работы прогностических моделей в смежных областях

Для обеспечения безопасности нефтедобывающих скважин могут быть адаптированы прогностические модели из других сфер применения. Одним из методов позволяющих решить эту задачу является трансферное обучение (перенос знаний, накопленных в модели ИИ для выполнения конкретной задачи, на схожую модель, разрабатываемую для другой задачи). Как правило, за основу берется предварительно обученная модель, обрабатывающая схожие структуры данных. Эта модель видоизменяется (например, удаляются последние слои) или берется без изменений. Далее она, как правило, дообучается на данных из предметной области. Трансфертное обучение позволяет сэкономить затраченные на обучение модели вычислительные ресурсы и сократить объем обучающей выборки.

Динамические характеристики временных рядов, получаемые в результате работы датчиков, установленных на нефтегазовом оборудовании, схожи с данными, получаемыми в результате работы множества других систем. В большинстве случаев отличия относятся именно к характеристикам самих телеметрических систем (частота дискретизации, единицы измерения), что в таком случае позволяет применять методы трансфертного обучения.

В [16] решена проблема прогнозирования кибератак на автоматизированную систему управления водоснабжением, в результате экспериментов была разработана модель, позволяющая с точностью 98,4 % предсказать отказ и спрогнозировать время ремонта системы. Модель основана на применении рекуррентных сетей с долгой краткосрочной памятью (LSTM), набор данных состоял из 220320 строк для каждого из 51 датчика, собирающих показания раз минуту на протяжении 6 месяцев. Состояние датчика определялось 3 вариантами (нормальная работа системы, восстановление работы датчика, датчик не работает). Обучение выполнялось алгоритмом Adam на протяжении 50 эпох.

В [17] ставилась задача анализа телеметрических данных космических аппаратов для прогнозирования поломок. Данные, которые собирает оборудование, и сенсоры космической техники являются многомерным временным рядами. Для обучения моделей ИИ в данной работе применялись ансамбли нейронных сетей и 3 набора данных, полученных с мониторов утечки хладагентов белорусского космического аппарата. Исходная выборка была разделена на три части: тренировочный, тестовый и

проверочные наборы (70 %, 15 %, 15 %). Размер скрытого слоя ENN (ансамбль нейронных сетей, ансамбль представляет собой совокупность обученных моделей, применяемых совместно для решения одной задачи), для трех наборов данных составлял соответственно 28, 30, 70 нейронов.

В статье [18] сравнивались различные подходы анализа данных телеметрии получаемых со спутников SAC (Центр по применению космической техники, Индия), для предсказания аварийных ситуаций на оборудовании спутника. Проведено сравнение методов машинного обучения, которые могут применяться для решения задачи: XGBoost (градиентный бустинг), модель авторегрессии ARIMA, SVM, а также нейросетевые модели RNN, MLP, LSTM. Всего в исследовании применялись два набора данных, разделенных на обучающую (70 %) и тестовую (30 %) выборки. Сделан вывод о превосходстве модели, основанной на рекуррентных сетях с долгой краткосрочной памятью. Среднеквадратичная ошибка модели составила 5,1 %, средняя абсолютная ошибка – 4 %.

Исследование [19] основано на решении проблемы долгосрочного прогнозирования данных телеметрии (данные электрических трансформаторов, почасовое потребление энергии, экономические показатели 8 стран за 26 лет, почасовые данные датчиков на дорогах, данные о погоде и данные заболеваний) с помощью апробированного исследователями метода автоформер. Автоформер (Autoformer) – это улучшение архитектуры трансформера (Transformer), который состоит из кодировщика и декодировщика (по аналогии с архитектурой «автокодировщик»), но в основе которых лежат механизмы самовнимания (self-attention). Метод по-прежнему следует структуре кодер-декодер, но преобразовывает трансформер в архитектуру для прогнозирования и декомпозиции. Автоформер способен постепенно выделять долгосрочную информации о тенденциях из предсказанных скрытых переменных, что в свою очередь позволяет обученной модели попеременно декомпонировать и уточнять промежуточные результаты. Также в исследовании используется механизм автокорреляции. Модель, опубликованная авторами, содержит 2 слоя кодировщика и 1 слой декодера, обучается на 6 наборах данных из разных областей. Обучение происходило на протяжении 10 эпох с помощью оптимизатора Adam. По сравнению с классической моделью трансформера снижение среднеквадратичной ошибки составило от 15 % до 74 %. Среднеквадратичная ошибка модели, при работе с телеметрическими данными составила 23,1 %.

В исследовании [20] ставится задача обнаружения аномалий работы гироскопа (гироскопа с управляющим моментом) на основе классификации рабочего состояния и двухэтапного трансферного обучения. Модель, предложенная авторами, представляет собой симбиоз LSTM и нейронной сети SincNet, основанной на использовании сверточных слоев (первый слой заменяется на свертку Sinc фильтров, подавляющих частоты в спектре сигнала выше определенного порога). ИНС обучалась на протяжении 100 эпох на наборах Марсианского разведывательного орбитального аппарата (MRO), активного пассивного спутника для определения влажности почвы (SMAP) и марсохода Марсианской научной лаборатории (MSL). Затем в модель вводится набор данных, основанный на показаниях датчиков, охватывающих полный жизненный цикл гироскопа в космосе (155 дней), разделенный на 16 классов (данные тока подвеса, температура вала и двигателя ротора, скорость и другие параметры). Тестовая выборка составила 20 % от общего объема данных. Экспериментальные результаты показали значение F-меры 91,6 %.

В научной работе [21] описано исследование одномерных и многомерных временных рядов, представляющих собой 6 эталонных наборов данных [26], для обнаружения аномалий в работе различных устройств. Обучение происходило на протяжении 96 эпох. Архитектура модели FEDformer состоит их трех основных частей:

FEV (блок, преобразующий временную область в частотную область), FEA (блок для преобразований в частотной области), MOED (блок декомпозиции). FEDformer в среднем показала на 22,6 % лучшие результаты, чем модель Autoformer. Для одномерных временных рядов уменьшение ошибки прогнозирования составило 14,8 %.

В публикации [22] описано решение задачи прогнозирования возраста и пола пользователей сотовой сети. Для решения задачи использовалась нейронная сеть прямого распространения с 7 слоями (5 скрытых, 1 входной и 1 выходной). Набор данных был предоставлен поставщиком услуг беспроводной связи из числа пользователей сотовых телефонов. Точность предсказания составила 78 %.

В [23] исследовалась возможность анализа временных рядов с помощью сверточной нейронной сети, которая использует гибридное экспоненциальное сглаживание (S-CNN). Коэффициент сглаживания составил 0,57. Для обучения модели применялись оптимизатор Adam и 4 набора данных, представляющих из себя данные сетевой телеметрии. Среднеквадратичная ошибка составила 1,2 %.

Статья [24] описывает решение задачи прогнозирования утечек аксиально-поршневого насоса с помощью рекуррентных нейронных сетей. Набор данных представлен временными рядами аксиально-поршневого насоса. Обучающая выборка составляла 70 %.

В статье [25] ставилась задача обнаружения аномалий в телеметрии космических аппаратов. Авторы исследовали возможность использования для решения этой задачи нейронной сети, основанной на LSTM, позволяющей учитывать микро- и макрохарактеристики телеметрических данных. Для обучения и тестирования использовались данные со спутников SMAP (спутники НАСА для мониторинга окружающей среды) и Beidou (спутники китайской навигационной системы), а также данные с марсохода Curiosity (марсоход НАСА третьего поколения). Обучающая выборка составила 70 %.

Исследование [26] посвящено поиску решения проблемы диагностики неисправности космических спутников. Источником телеметрических данных являлся египетский спутник Egyptosat-1. Классификация происходила с помощью LAD (логического анализа данных), FTA (деревья отказов) и нейронной сети. Обучающая выборка составила 20 %, для валидации использовалось 30 % данных и 50 % для тестирования.

В научной работе [27] ставилась задача интеллектуального анализа данных телеметрической информации бортовой аппаратуры малых космических аппаратов. Авторы сравнивают различные нейросетевые модели. Также в работе предлагается гибридная нейросетевая модель Hybrid_NN_TD_AIST, состоящая из трех блоков слоев: сверточного одномерного блока CNN, рекуррентного GRU и итогового полносвязного блока-классификатора с применением слоя агрегации AveragePooling и метода проброса остаточных связей семейства архитектур ResNet. Точность классификации составила 98,5 % (обучающая, валидационная и тестовая выборки составили 65 %, 15 % и 20 %).

Конфронтативные данные исследований приведены в Таблице 3.

Таблица 3 – Сопоставительные данные по нейросетевым моделям для анализа телеметрических данных

Table 3 – Comparative data on neural network models for analyzing telemetry data

Архитектура ИНС	Данные	Результат	Источник литературы
LSTM (2 слоя LSTM по 8 нейронов и полносвязный слой с одним нейроном)	Набор данных состоял из показаний 51 датчиков, которые собирают данные о работе водяного насоса (220320 строк)	Точность (Accuracy) 98,4 %	[16]
ENN (28 нейронов в скрытом слое)	3 набора данных, частота дискретизации 1, 2 и 10 Гц	Среднеквадратическая ошибка (RSE) 1,5 %	[17]
LSTM (3 скрытых слоя, 20 нейронов в каждом)	2 набора данных полученных от SAC, состоящие из 2580 строк	Среднеквадратическая ошибка (RSE) 5,1 %	[18]
Autoformer (2 слоя кодировщика и 1 слой декодировщика)	6 наборов данных из различных областей (данные электрических трансформаторов, почасовое потребление энергии, экономические показатели 8 стран за 26 лет, почасовые данные датчиков на дорогах, данные о погоде и данные заболеваний)	Среднеквадратическая ошибка (RSE) 23,1 %	[19]
LSTM (3 скрытых слоя, каждый 288 нейронов) + SincNet (96 Sinc фильтров)	3720 сегментов в каждом из 16 классов (телеметрические данные с гиродина)	F-мера (F-score) 91,6 %	[20]
FEDformer (24 слоя)	Набор данных из [17]	Среднеквадратическая ошибка (RSE) 17,8 %	[21]
FNN (7 слоев: входной 11 нейронов, 3 Dropout, 2 скрытых слоя с Relu на 36 и 108 нейронов, выходной слой из 48 нейронов с softmax)	Набор данных из 14549 образов сетевой телеметрии, по 1688 признаков в каждом	Точность (Accuracy) 78 %	[22]
S-CNN (81 слой: 3 сверточных слоя с Relu, 1 Flatten и 1 Pooling, 76 полносвязных слоев с 100 нейронами)	4 набора временных рядов (сетевая телеметрия). Каждый набор содержал 365 строк	Среднеквадратическая ошибка (RSE) 1,2 %	[23]

Таблица 3 (продолжение)
Table 3 (extended)

Архитектура ИНС	Данные	Результат	Источник литературы
LSTM (2 скрытых слоя по 5 и 8 нейронов)	7215 показаний 20, частота дискретизации 1 Гц	Среднеквадратическая ошибка (RSE) 2 %	[24]
LSTM (2 скрытых слоя, 10 нейронов в каждом)	3 набора данных с космических аппаратов, 2000 строк	Точность (Accuracy) 91,2 %	[25]
ENN (20 нейронов в скрытом слое)	Набор данных космического спутника Egyptosat-1	Среднеквадратическая ошибка (RSE) 2,89 %	[26]
Hybrid_NN_TD_AIST (3 блока слоев)	Набор телеметрический данных космического аппарата, 2679 строк	Точность (Accuracy) 98,5 %	[27]

Обсуждение

По причине использования различных наборов данных существующие модели сложно поддаются сравнению. Поэтому судить о достоверности достигнутых результатов в ряде случаев также затруднительно. Исключением является несколько работ, где использован набор данных $3W^3$, однако в данных публикациях постулируются более скромные результаты. Можно также видеть, что при малых наборах данных, каким и является $3W$, предпочтение стоит отдавать более простым моделям ИИ, так как их гораздо проще обучить, но их потенциал гораздо ниже (при наличии больших объемов выборки, глубокие нейросетевые модели показывают наилучший результат).

В смежных областях большинство исследователей использует рекуррентные сети с долгой краткосрочной памятью (обычно в сочетании со сверточными ИНС). Многие исследования улучшают уже существующие архитектуры [10-11]. Наилучшие показатели точности были достигнуты рекуррентными сетями [16]. Перспективной архитектурой также являются сети-трансформеры [21]. Следует отметить, что в задачах предиктивной диагностики нефтегазового оборудования они не распространены, хотя их применение может дать положительный эффект.

Мы можем видеть, что наиболее глубокая нейросетевая модель для нефтегазовой сферы включает 7 слоев (Таблица 2). Для смежных отраслей известны модели, насчитывающие 24 [21], 81 [23] слоев (Таблица 3). Подобные глубокие архитектуры невозможно обучить «с нуля» на открытых наборах данных^{1,2,3}. Эти наборы данных имеют малый объем. Формирование большого набора данных с нуля проблематично. Инциденты происходят относительно редко, но приносят много убытков. Однако такие архитектуры, как FEDformer [21] и S-CNN [23] могут быть использованы в нефтегазовой сфере. Рассмотренные нейросетевые модели в нефтегазовой и смежных отраслях анализируют схожие структуры данных. Предварительно обученные нейронные сети могут быть дообучены и адаптированы для использования на этапе предварительной обработки данных в задачах анализа нефтегазовой телеметрии.

Заключение

Проведенный обзор показал, что в задаче предсказания отказов насосно-компрессорного оборудования в нефтегазовой отрасли обычно используются относительно малые ИНС, с небольшим количеством слоев (от 1 до 5, максимум 7). Большие архитектуры обучить затруднительно. Но если брать во внимание другие предметные области (помимо нефтегазовой), в целом в задачах предиктивной диагностики оборудования часто применяются гораздо более глубокие и производительные архитектуры.

Хотя в некоторых работах постулируются достаточно высокие результаты, обычно они получены при тестировании на сравнительно малых выборках или закрытых наборах данных. В реальной практике, как правило, такие показатели повторить не получается.

Проблематика дрейфа данных опускается или не рассматривается исследователями (возможно, данные с течением времени не меняют своих свойств кардинально или пока не накоплено достаточной статистики, чтобы зафиксировать наличие проблемы).

Собрать обучающие данные достаточного объема за приемлемое время проблематично. В таких случаях требуется модель, способная дообучиться на относительно малой выборке. В качестве этих моделей можно использовать предварительно обученные сети с архитектурой трансформер, которые лучше всего справляются с задачами прогнозирования временных рядов. При этом в распоряжении исследователя часто имеется только один из открытых наборов данных весьма ограниченного объема, большинство из которых имеют значительное количество пропусков значений и плохо сбалансированы (одним из лучших вариантов является набор данных 3W).

В качестве направлений будущих исследований авторы предлагают применять технологии трансферного обучения, используя глубокие нейросетевые модели для анализа временных рядов с целью предварительной обработки данных телеметрии и извлечения признаков. Извлеченные признаки планируется обрабатывать с помощью неглубоких нейросетевых моделей, независимо обученных на открытых наборах данных.

СПИСОК ИСТОЧНИКОВ

1. Geeta Y., Kolin P. Architecture and security of SCADA systems. *International Journal of Critical Infrastructure Protection*. 2021;34:100433. DOI: 10.1016/j.ijcip.2021.100433.
2. Тчаро Х., Воробьев А.Е. Цифровизация нефтяной промышленности: базовые подходы и обоснование "интеллектуальных" технологий. *Вестник евразийской науки*. 2018;10(2):77.
3. Anirbid S., Kriti Y. Application of machine learning and artificial intelligence in oil and gas industry. *Petroleum Research*. 2021;6(4):379–391. DOI: 10.1016/j.ptlrs.2021.05.009.
4. Хамидулин Т.Г. Применение искусственных нейронных сетей. *Экономика и социум*. 2017;38(7):313–318.
5. Zhou D., Huang D. Vibration-based fault diagnosis of the natural gas compressor using adaptive stochastic resonance realized by Generative Adversarial Networks. *Engineering Failure Analysis*. 2020;116:104759. DOI: 10.1016/j.engfailanal.2020.104759.
6. Топольников А.С. Машинное обучение для механизированной добычи нефти. *Деловой журнал «Neftegaz.RU»*. 2021;5:14–19. URL: <https://magazine.neftegaz.ru/articles/dobycha/682013-mashinnoe-obuchenie-dlya-mekhanizirovannoy-dobychi-nefti> [дата обращения: 27.10.2023].

7. Wong P., Wong W.K. A minimalist approach for detecting sensor abnormality in oil and gas platforms. *Petroleum Research*. 2022;7(2):177–185. DOI: 10.1016/j.ptlrs.2021.09.007.
8. Вершинин В.Е. Нейросетевое моделирование: прогнозирование показателей добычи скважин в условиях нестационарного заводнения. *Деловой журнал «Neftegaz.RU»*. 2022;5:26–32. URL: <https://magazine.neftegaz.ru/articles/tsifrovizatsiya/740217-neyrosetevoe-modelirovanie-prognozirovanie-pokazateley-dobychi-skvazhin-v-usloviyakh-nestatsionarnog/?ysclid=ldwqmqq0bh84798351> [дата обращения: 27.10.2023].
9. Dyer A.S., Zaengle D. Applied machine learning model comparison: Predicting offshore platform integrity with gradient boosting algorithms and neural networks. *Marine Structures*. 2022;83:103152. DOI: 10.1016/j.marstruc.2021.103152.
10. Kozlenko M., Kuz M. Fault diagnosis of natural gas pumping unit based on machine learning. *6th International Scientific and Practical Conference on Applied Systems and Technologies in the Information Society*. 2022;4:271. DOI: 10.5281/zenodo.7409180.
11. Wu Y., Feng Z. Fault diagnosis algorithm of beam pumping unit based on transfer learning and DenseNet model. *Applied sciences*. 2022;21(12):11091. DOI: 10.3390/app122111091.
12. Yolchuyev A. Feed-forward neural network based petroleum wells equipment failure prediction. *Engineering*. 2023;15(3):163–175. DOI: 10.4236/eng.2023.153013.
13. Li Y., Ge T. Imminence monitoring of critical events: a representation learning approach. In: *Proceedings of the 2021 International Conference on Management of Data (SIGMOD '21)*. Association for Computing Machinery, New York, USA, 2021. p. 1103–1115. DOI: 10.1145/3448016.3452804
14. Carvalho B.G. Evaluating machine learning techniques for detection of flow instability events in offshore oil wells. *Universidade Federal do Espírito Santo*. 2021;1:1–59.
15. Marins M.A., Barros B.D. Fault detection and classification in oil wells and production/service lines using random forest. *Journal of Petroleum Science and Engineering*. 2021;197:107879. DOI: 10.1016/j.petrol.2020.107879.
16. Асяев Г.Д., Соколов А.Н. Модели предиктивной защиты информации автоматизированной системы управления водоснабжением на основе временных рядов с использованием технологий машинного обучения. *Вестник УрФО. Безопасность в информационной сфере*. 2021;4(42):39–45.
17. Marushko E.E., Doudkin A.A. Ensembles of neural networks for forecasting of time series of spacecraft telemetry. *Optical Memory and Neural Networks*. 2017;26(1):47–54. DOI: 10.3103/S1060992X17010064.
18. Jain R., Rohit M. Prediction of telemetry data using machine learning techniques. *International Journal of Engineering Research & Technology*. 2022;11(9). DOI: 10.17577/IJERTV11IS090048.
19. Wu H., Xu J. Autoformer: decomposition transformers with auto-correlation for long-term series forecasting. *Arxiv*. 2022;5. DOI:0.48550/arXiv.2106.13008.
20. Zhang K., Wang S.C. Anomaly detection of control moment gyroscope based on working condition classification and transfer learning. *Applied sciences*. 2023;13(7):4259–9. DOI: 10.3390/app13074259.
21. Zhou T., Ziqing M. FEDformer: frequency enhanced decomposed transformer for long-term series forecasting. *Arxiv*. 2022;3. DOI: 10.48550/arXiv.2201.12740.
22. Kuang L., Pobbathi S. Predicting age and gender from network telemetry: Implications for privacy and impact on policy. *PLoS ONE* 2022;17(7):e0271714. DOI: 10.1371/journal.pone.0271714.
23. Wibawa A.P., Elmunsyah H. Time-series analysis with smoothed Convolutional Neural Network. *Journal of Big Data*. 2022;9(1). DOI: 10.1186/s40537-022-00599-y

24. Özmen Ö., Sinanoğlu C. Prediction of leakage from an axial piston pump slipper with circular dimples using deep neural networks. *Chinese Journal of Mechanical Engineering*. 2020;33(1). DOI: 10.1186/s10033-020-00443-5.
25. Yang L., Ma Y. Improved deep learning-based telemetry data anomaly detection to enhance spacecraft operation reliability. *Microelectronics Reliability*. 2021;126. DOI: 10.1016/j.microrel.2021.114311.
26. Ibrahim S., Ayman A. Machine learning techniques for satellite fault diagnosis. *Ain Shams Engineering Journal*. 2020;11(1). DOI: 10.1016/j.asej.2019.08.006
27. Скобцов В.Ю., Соколов Б.В. Гибридные нейросетевые модели в задаче мультиклассовой классификации данных телеметрической информации малых космических аппаратов. *Вестник ВГУ. Серия: Системный анализ и информационные технологии*. 2022;10(3):99.

REFERENCES

1. Geeta Y., Kolin P. Architecture and security of SCADA systems. *International Journal of Critical Infrastructure Protection*. 2021;34:100433. DOI: 10.1016/j.ijcip.2021.100433.
2. Tchareo H., Vorobiev A.E. Digitalization of the oil industry: basic approaches and justification of “smart” technologies. *Vestnik evraziyskoy nauki*. 2018;10(2):77. (In Russ.).
3. Anirbid S., Kriti Y. Application of machine learning and artificial intelligence in oil and gas industry. *Petroleum Research*. 2021;6(4):379–391. DOI: 10.1016/j.ptlrs.2021.05.009.
4. Hamidulin T.G. Primenenie iskustvennih neyronnykh setey. *Ekonomika i socium*. 2017;38(7):313–318. (In Russ.).
5. Zhou D., Huang D. Vibration-based fault diagnosis of the natural gas compressor using adaptive stochastic resonance realized by Generative Adversarial Networks. *Engineering Failure Analysis*. 2020;116:104759. DOI: 10.1016/j.engfailanal.2020.104759.
6. Topol'nikov A.S. Mashinnoe obuchenie dlya mekhanizirovannoy dobychi nefti. *Delovoy zhurnal Neftegaz.RU*. 2021;5:14–19. URL: <https://magazine.neftegaz.ru/articles/dobycha/682013-mashinnoe-obuchenie-dlya-mekhanizirovannoy-dobychi-nefti> [accessed on 27.10.2023].
7. Wong P., Wong W.K. A minimalist approach for detecting sensor abnormality in oil and gas platforms. *Petroleum Research*. 2022;7(2):177–185. DOI: 10.1016/j.ptlrs.2021.09.007.
8. Vershinin V.E. Neyrosetevoe modelirovanie: prognozirovanie pokazateley dobychi skvazhin v usloviyakh nestatsionarnogo zavodneniya. *Delovoy zhurnal Neftegaz.RU*. 2022;5:26–32. URL: <https://magazine.neftegaz.ru/articles/tsifrovizatsiya/740217-neyrosetevoe-modelirovanie-prognozirovanie-pokazateley-dobychi-skvazhin-v-usloviyakh-nestatsionarnog/?ysclid=ldwqmqq0bh84798351> [accessed on 27.10.2023]. (In Russ.).
9. Dyer A.S., Zaengle D. Applied machine learning model comparison: Predicting offshore platform integrity with gradient boosting algorithms and neural networks. *Marine Structures*. 2022;83:103152. DOI: 10.1016/j.marstruc.2021.103152.
10. Kozlenko M., Kuz M. Fault diagnosis of natural gas pumping unit based on machine learning. *6th International Scientific and Practical Conference on Applied Systems and Technologies in the Information Society*. 2022;4:271. DOI: 10.5281/zenodo.7409180.
11. Wu Y., Feng Z. Fault diagnosis algorithm of beam pumping unit based on transfer learning and DenseNet model. *Applied sciences*. 2022;21(12):11091. DOI: 10.3390/app122111091.
12. Yolchuyev A. Feed-forward neural network based petroleum wells equipment failure prediction. *Engineering*. 2023;15(3):163–175. DOI: 10.4236/eng.2023.153013.

13. Li Y., Ge T. Imminence monitoring of critical events: a representation learning approach. In: *Proceedings of the 2021 International Conference on Management of Data (SIGMOD '21)*. Association for Computing Machinery, New York, USA, 2021. p. 1103–1115. DOI: 10.1145/3448016.3452804
14. Carvalho B.G. Evaluating machine learning techniques for detection of flow instability events in offshore oil wells. *Universidade Federal do Espírito Santo*. 2021;1:1–59.
15. Marins M.A., Barros B.D. Fault detection and classification in oil wells and production/service lines using random forest. *Journal of Petroleum Science and Engineering*. 2021;197:107879. DOI: 10.1016/j.petrol.2020.107879.
16. Asyaev G.D., Sokolov A.N. Predictive information protection models of automated water management system based on time series using machine learning technologies. *Vestnik UrFO Bezopasnost' v informatsionnoy sfere = Vestnik UrFO. Security in the Information Sphere*. 2021;42(4):39–45. (In Russ.).
17. Marushko E.E., Doudkin A.A. Ensembles of neural networks for forecasting of time series of spacecraft telemetry. *Optical Memory and Neural Networks*. 2017;26(1):47–54. DOI: 10.3103/S1060992X17010064.
18. Jain R., Rohit M. Prediction of telemetry data using machine learning techniques. *International Journal of Engineering Research & Technology*. 2022;11(9). DOI: 10.17577/IJERTV11IS090048.
19. Wu H., Xu J. Autoformer: decomposition transformers with auto-correlation for long-term series forecasting. *Arxiv*. 2022;5. DOI:0.48550/arXiv.2106.13008.
20. Zhang K., Wang S.C. Anomaly detection of control moment gyroscope based on working condition classification and transfer learning. *Applied sciences*. 2023;13(7):4259–9. DOI: 10.3390/app13074259.
21. Zhou T., Ziqing M. FEDformer: frequency enhanced decomposed transformer for long-term series forecasting. *Arxiv*. 2022;3. DOI: 10.48550/arXiv.2201.12740.
22. Kuang L., Pobbathi S. Predicting age and gender from network telemetry: Implications for privacy and impact on policy. *PLoS ONE* 2022;17(7):e0271714. DOI: 10.1371/journal.pone.0271714.
23. Wibawa A.P., Elmunsyah H. Time-series analysis with smoothed Convolutional Neural Network. *Journal of Big Data*. 2022;9(1). DOI: 10.1186/s40537-022-00599-y
24. Özmen Ö., Sinanoğlu C. Prediction of leakage from an axial piston pump slipper with circular dimples using deep neural networks. *Chinese Journal of Mechanical Engineering*. 2020;33(1). DOI: 10.1186/s10033-020-00443-5.
25. Yang L., Ma Y. Improved deep learning-based telemetry data anomaly detection to enhance spacecraft operation reliability. *Microelectronics Reliability*. 2021;126. DOI: 10.1016/j.microrel.2021.114311.
26. Ibrahim S., Ayman A. Machine learning techniques for satellite fault diagnosis. *Ain Shams Engineering Journal*. 2020;11(1). DOI: 10.1016/j.asej.2019.08.006
27. Skobtsov V., Sokolov B. Hybrid neural network models in the problem of telemetry data multiclass classification of small spacecrafts. *Vestnik VGU. Seriya: Sistemnyi analiz i informatsionnye tekhnologii = Proceedings of Voronezh State University. Series: Systems Analysis and Information Technologies*. 2022;(3):99. DOI: 10.17308/sait/1995-5499/2022/3/99-114. (In Russ.).

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Сулавко Алексей Евгеньевич, доктор технических наук, доцент кафедры «Комплексная защита информации», Омский **Aleksey E. Sulavko**, Doctor of Engineering Sciences, Associate Professor at the Department of Comprehensive Information Protection, Omsk

государственный технический университет,
Омск, Российская Федерация.

e-mail: sulavich@mail.ru

ORCID: [0000-0002-9029-8028](https://orcid.org/0000-0002-9029-8028)

State Technical University, Omsk, the Russian
Federation.

Васильев Владимир Иванович, доктор
технических наук, профессор, профессор
кафедры вычислительной техники и защиты
информации, Уфимский университет науки и
технологий, Уфа, Российская Федерация.

e-mail: vas0015@yandex.ru

ORCID: [0000-0002-6105-5481](https://orcid.org/0000-0002-6105-5481)

Vladimir I. Vasilyev, Doctor of Engineering
Sciences, Professor at the Department of
Computer Technology and Information Security,
Ufa University of Science and Technology, Ufa,
the Russian Federation.

Клиновенко Сергей Александрович,
аспирант, Омский государственный
технический университет, Омск, Российская
Федерация.

e-mail: sergey.klinovenko@gmail.com

Sergey A. Klinovenko, Postgraduate Student,
Omsk State Technical University, Omsk, the
Russian Federation.

Ложников Павел Сергеевич, доктор
технических наук, доцент, заведующий
кафедрой "Комплексная защита
информации", Омский государственный
технический университет, Омск, Российская
Федерация.

e-mail: lozhnikov@mail.ru

ORCID: [0000-0001-7878-1976](https://orcid.org/0000-0001-7878-1976)

Pavel S. Lozhnikov, Doctor of Engineering
Sciences, Associate Professor, Head of the
Department of Comprehensive Information
Protection, Omsk State Technical University,
Omsk, the Russian Federation.

Сувырин Георгий Антонович, аспирант
кафедры "Математические методы и
информационные технологии в экономике",
Омский государственный технический
университет, Омск, Российская Федерация.

e-mail: suvyrin1999@gmail.com

ORCID: [0000-0001-6160-6573](https://orcid.org/0000-0001-6160-6573)

Georgii A. Suvyrin, Postgraduate Student,
Mathematical Methods and Information
Technologies in Economics Department, Omsk
State Technical University (OmSTU), Omsk, the
Russian Federation.

Гузайров Мурат Бакеевич, доктор
технических наук, профессор, профессор
кафедры управления информационной
безопасностью, Уфимский университет науки
и технологий, Уфа, Российская Федерация.

e-mail: guzairov@rb.ru

Murat B. Guzairov, Doctor of Engineering
Sciences, Professor, Professor at the Department
at the "Information security management", Ufa
University of Science and Technology, Ufa, the
Russian Federation.

*Статья поступила в редакцию 06.11.2023; одобрена после рецензирования 21.02.2024;
принята к публикации 04.03.2024.*

*The article was submitted 06.11.2023; approved after reviewing 21.02.2024;
accepted for publication 04.03.2024.*