

Применение методов машинного обучения в системах моделирования технологических процессов

Application of machine learning methods in technological process modeling systems

УДК 004.7

Получено: 15.02.2025

Одобрено: 20.03.2025

Опубликовано: 25.04.2025

Рогов Н.

Магистрант, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого», г. Санкт-Петербург
e-mail: rogov2.n@edu.spbstu.ru

Rogov N.

Master's Degree Student, Peter the Great St. Petersburg Polytechnic University, St. Petersburg
e-mail: rogov2.n@edu.spbstu.ru

Ростова О.В.

Канд. экон. наук, доцент, доцент Высшей школы бизнес-инжиниринга, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого», г. Санкт-Петербург
e-mail: o.rostova_isem@mail.ru

Rostova O.V.

Candidate of Economic Sciences, Associated Professor of Higher School of Business Engineering, Peter the Great St. Petersburg Polytechnic University, St. Petersburg
e-mail: o.rostova_isem@mail.ru

Тебекин А.В.

Д-р техн. наук, д-р экон. наук, профессор, почетный работник науки и техники Российской Федерации, профессор кафедры менеджмента, ФГАОУ ВО «Московский государственный институт международных отношений (Университета) Министерства иностранных дел Российской Федерации», г. Москва
e-mail: Tebekin@gmail.com

Tebekin A.V.

Doctor of Technical Sciences, Doctor of Economic Sciences, Professor, Honorary Worker of Science and Technology of the Russian Federation, Professor of the Department of Management, Moscow State Institute of International Relations (University) of the Ministry of Foreign Affairs of the Russian Federation, Moscow
e-mail: Tebekin@gmail.com

Широкова С.В.

Канд. техн. наук, доцент, доцент Высшей школы бизнес-инжиниринга, ФГАОУ ВО «Санкт-Петербургский политехнический университет Петра Великого», г. Санкт-Петербург
e-mail: swchirokov@mail.ru

Shirokova S.V.

Candidate of Technical Sciences, Associate Professor, Associate Professor of the Higher School of Business Engineering, Peter the Great St. Petersburg Polytechnic University, St. Petersburg
e-mail: swchirokov@mail.ru

Аннотация

В статье рассматривается применение методов машинного обучения в системах моделирования технологических процессов с целью прогнозирования состояния оборудования в различных отраслях промышленности. Актуальность темы обусловлена необходимостью повышения эффективности производственных операций в условиях растущей конкуренции и быстро меняющейся рыночной среды. В работе представлен обзор современных систем моделирования технологических процессов, а также описаны области их применения. Особое внимание уделено таким методам прогнозирования, как линейная регрессия, рекуррентные нейронные сети долгосрочной памяти и авторегрессионная интегрированная модель скользящего среднего. В практической части проведен анализ данных, а также эксперимент по прогнозированию значений температуры с использованием указанных методов. Полученные результаты показали, что для используемых данных более высокую точность прогнозирования обеспечивают модели LSTM и ARIMA.

Ключевые слова: системы моделирования процессов, моделирование, прогнозирование, импортозамещение, нефтепереработка, нефтегазовая промышленность, машинное обучение, линейная регрессия, LSTM, ARIMA, оптимизация процессов, технологические процессы.

Abstract

This article considers the application of machine learning methods in process modeling systems to predict the state of equipment in various industries. The relevance of the topic is due to the need to improve the efficiency of production operations in an increasingly competitive and rapidly changing market environment. The paper presents a review of modern technological process modeling systems and describes their application areas. Special attention is paid, to such forecasting methods as linear regression, recurrent neural networks of long-term memory and autoregressive integrated moving average model. In the practical part, data analysis as well as an experiment for predicting temperature values using the above-mentioned methods was carried out. The results showed that for the data used, the LSTM and ARIMA models provide higher prediction accuracy.

Keywords: process modeling systems, modeling, prediction, import substitution, refinery, oil and gas industry, machine learning, linear regression, LSTM, ARIMA, process optimization, technological processes.

Введение

В последние годы методы машинного обучения стали активно использоваться в различных промышленных системах, в том числе и системах моделирования технологических процессов. Применение технологий машинного обучения в данных системах позволяет более эффективно анализировать сложные процессы, оптимизировать параметры работы оборудования, а также прогнозировать состояние различных технологических процессов.

Одним из ключевых аспектов применения методов машинного обучения в моделировании технологических процессов является способность автоматически извлекать закономерности из больших объемов данных. Это особенно актуально в условиях современных промышленных предприятий, где собирается огромное количество информации о производственных процессах. Применение методов машинного обучения в системах моделирования способствует принятию более обоснованных решений.

Актуальность темы обусловлена необходимостью повышения эффективности производственных операций в условиях растущей конкуренции и быстро меняющейся рыночной среды [1 - 5].

Цель исследования

Данное исследование посвящено применению методов машинного обучения для повышения эффективности систем моделирования технологических процессов в промышленном производстве. Современные промышленные предприятия оперируют огромными массивами данных, получаемых от различных датчиков и контроллеров, описывающих состояние оборудования, параметры технологических параметров и выходные характеристики продукции. Традиционные методы моделирования, часто основанные на физических уравнениях и экспертных знаниях, зачастую оказываются недостаточно гибкими и точными для обработки многомерных данных, когда производственные процессы постоянно изменяются, а, кроме того, присутствуют случайные возмущения.

Таким образом, применение алгоритмов машинного обучения представляет собой перспективное направление. В рамках данного исследования были поставлены и решены следующие задачи:

1) Изучение существующих систем моделирования технологических процессов и их приложений. Данный этап включал в себя анализ существующих программных решений для моделирования, таких как Aspen Plus, gPROMS и COMSOL Multiphysics, и оценку их преимуществ и недостатков с точки зрения интеграции с методами машинного обучения. Особое внимание уделялось технологическим процессам, где эти методы могут быть особенно эффективны, например, при оптимизации работы химических реакторов, прогнозировании износа оборудования в металлургической промышленности или прогнозировании качества продукции в пищевой промышленности. Было проанализировано, как существующие системы могут быть улучшены с помощью машинного обучения, и определены наиболее полезные архитектуры взаимодействия.

2) Анализ методов прогнозирования временных рядов. В рамках этой задачи исследовались различные подходы к прогнозированию временных рядов, подходящие для анализа данных о технологическом процессе. Сюда входят классические методы, такие как модели авторегрессии (AR) и интегрированного скользящего среднего (ARIMA), модели экспоненциального сглаживания (Holt-Winters), так и современные методы машинного обучения, такие как рекуррентные нейронные сети (RNN), в частности, LSTM и GRU сети, а также прогнозирование на основе трансформаторов (например, архитектура Transformer). Выбор метода зависит от специфики данных, наличия трендов, сезонности и других характеристик временных рядов. В исследовании было проведено сравнение методов с точки зрения сложности их реализации, вычислительной эффективности и точности прогнозов.

3) Обучение моделей для прогнозирования данных. На этом этапе осуществлялось обучение выбранных моделей на реальных или синтетических данных, представляющих технологические процессы. Процесс обучения включает в себя предварительную обработку данных (очистка от выбросов, нормализация, обработка пропущенных значений), выбор архитектуры модели, подбор гиперпараметров с использованием методов кросс-валидации, а также оценку качества обучения на валидационной выборке. Выбор метрик качества зависит от задачи прогнозирования, но может включать в себя среднеквадратическую ошибку (MSE), среднюю абсолютную ошибку (MAE), R-квадрат и др. Важно учитывать возможные ограничения по объему данных и вычислительной мощности.

4) Сравнительный анализ качества прогнозных моделей. После обучения нескольких моделей осуществлялся сравнительный анализ их качества прогнозирования на тестовой выборке, которая не использовалась в процессе обучения. Этот анализ позволил определить наиболее эффективную модель для конкретного технологического процесса. Кроме сравнения метрик качества, важно оценить устойчивость моделей к шуму и изменению условий работы. Результаты сравнения использованы для формулирования рекомендаций по выбору и применению методов машинного обучения в конкретных промышленных задачах.

В итоге, работа содержит не только технические результаты, но и практические рекомендации для внедрения разработанных подходов.

Производственные системы моделирования технологических процессов позволяют создавать цифровые двойники физических процессов в виде математических моделей с учетом физических, химических и технических аспектов.

На сегодняшний день на российском рынке систем моделирования используются решения, как и импортных, так и отечественных вендоров (табл. 1). Лидерами в этой области можно назвать: Aspen HYSYS, KBC Petro-Sim, Honeywell UniSim, Aveva PRO/II [6]. Начиная с 2022 г., рынок стал активно пополняться отечественным ПО.

Ярким примером являются продукты NAUKA.Proxima, AeroSIM, GIBBS и МиР ПиА Процесс+ (табл. 1).

Таблица 1

Системы имитационного моделирования процессов

Продукт	Компания	Страна
Aspen HYSYS	AspenTech	США
KBC Petro-Sim	KBC Advanced Technologies	Великобритания
Aveva PRO/II	AVEVA Group plc	Великобритания
Chemcad	Chemstations	США
UniSim	Honeywell	США
DWSIM (opensource GNU GPL/LGPL)		Бразилия
gPROMS ModelBuilder	PSE Ltd	Великобритания
NAUKA.Proxima	ООО «НАУКА»	Россия
AeroSYM	ООО «АЭРОГАЗ»	Россия
GIBBS		Россия
МиР ПиА Процесс+	ООО «МИР ПИА»	Россия

Методологическая база исследования

Промышленное моделирование технологических процессов помогает оптимизировать производственные операции, увеличить производительность и эффективность оборудования и снизить потери материалов и энергии. Также стоит учесть, что моделирование позволяет анализировать риски и безопасность в различных технологических процессах, выявлять потенциальные опасности и разрабатывать меры по их предотвращению [7 - 10]. Моделирование процессов широко распространено в отраслях, представленных на рис. 1 [11 - 15].

В химической отрасли системы используются для моделирования процессов на химических заводах, включая производство основных химических веществ, удобрений, пластмасс и других продуктов.

В нефтегазовой отрасли системы применяются для моделирования процессов добычи, переработки и транспортировки нефти и газа, а также расчёты на различных этапах производства: от добычи на месторождении до отгрузки конечных продуктов, таких как бензин, дизельное топливо, мазут и др.

В энергетической отрасли системы используются для моделирования энергетических процессов, таких как генерация пара, производство электроэнергии и процессы, связанные с использованием альтернативных источников энергии.

В фармацевтической отрасли системы позволяют моделировать процессы производства лекарственных средств, от синтеза активных ингредиентов до различных этапов очистки и упаковки.

В пищевой отрасли системы используются для моделирования процессов производства пищевых продуктов, включая молочные продукты, напитки, масло и другие товары.



Рис. 1. Области применения систем моделирования

Также стоит отметить активное использование систем моделирования в сфере образования с целью формирования практических навыков работы у будущих специалистов в области промышленности [16 - 18]. Системы моделирования используются для проведения научных исследований, анализа технологических процессов, выполнения практических работ [19 - 21]. На современном этапе использование машинного обучения позволяет системам учиться и улучшать свои возможности на основе данных и опыта.

В отличие от традиционного программирования, когда разработчик явно задает инструкции, используемые системой, в машинном обучении модель обучается на основе предоставленных данных, а результаты обучения становятся основой для принятия дальнейших решений [22, 23].

Были исследованы «обучение с учителем», когда модель обучается на размеченных данных и «без учителя», когда модель обучается на неразмеченных данных. В этом случае модель пытается найти скрытые структуры или закономерности в данных без явных меток [24].

Кроме того, исследован вариант «обучения с частичным привлечением учителя. Этот подход, который сочетает преимущества как обучения с учителем, так и обучения без него. В этом методе модель обучается на данных, где только некоторая часть имеет разметку. Важно отметить, что данный тип обучения может быть особенно полезен в случаях, когда сложно получить размеченные данные.

Широко используемым методом прогнозирования данных является линейная регрессия, как один из простых методов, позволяющих оценить зависимость между переменными и сформировать прогноз [25].

Рекуррентные нейронные сети (RNN) используют информацию о предшествующих вычислениях для последующей работы с данными, что позволяет им работать с такими типами данных, как текст или временные ряды [26].

Одна из основных проблем RNN заключается в том, что они теряют способность связывать информацию на больших расстояниях, что ограничивает их применение в задачах, требующих учета долгосрочного контекста. LSTM были разработаны для решения проблемы долговременных зависимостей, позволяя эффективно запоминать информацию на длительные периоды времени.

Модель ARIMA включает в себя авторегрессионную часть, интегрированную часть и часть скользящего среднего.

Процесс построения модели включает в себя несколько этапов:

- идентификация модели;
- оценивание параметров;
- тестирование модели;
- использование модели для прогнозирования.

Для определения порядка модели используются графики автокорреляционной функции (ACF) и частной автокорреляционной функции (PACF). Эти графики помогают определить, какие параметры следует использовать в модели.

Оценка параметров модели обычно осуществляется с помощью метода наименьших квадратов.

Важно, чтобы остатки модели были близки к белому шуму, что подразумевает отсутствие автокорреляции и постоянство дисперсии [27 - 29].

Практическая реализация

Для практического эксперимента используется временной ряд, который включает в себя информацию о параметрах работы диэтанализера в рамках блока абсорбции и ректификации газофракционирующей установки [30], входящей в состав производственного комплекса одного из нефтеперерабатывающих предприятий на территории Российской Федерации [31]. Принципиальная схема блока абсорбции и ректификации газофракционирующей установки представлена на рис. 2.




Рис. 2. Схема абсорбционно-ректификационной установки газофракционирующего завода

Описание оборудования, а также потоков сырья и продуктов, используемого на схеме, представлено в табл. 2.

**Описание модели блока абсорбции и ректификации
газофракционирующей установки**

Номер позиции на схеме	Наименование	Наименование в системах моделирования
1	Деэтанализатор	K-100
2	Пропановая колонна	K-2
3	Бутановая колонна	K-4
4	Изобутановая колонна	K-6
5	Пентановая колонна	K-7
6	Изопентановая колонна	K-8
A	Сырье	0-30, 0-43
B	Сухой газ	15
C	Пропановая фракция	2
D	Изопропановая фракция	6
E	Бутановая фракция	7
F	Изопентановая фракция	10
G	Пентановая фракция	11
H	Фракция C ₄ и выше	9

Данные, используемые для эксперимента, были получены в результате моделирования блока абсорбции и ректификации в программном продукте NAUKA.Proxima [32]. Размерность датасета составляет 31 391 запись и 8 столбцов.

На рис. 3 представлены данные по работе диэтанайзера.

```
df.head()
```

Unnamed: 0	Date	Temperature	Season	Temperature K-100	Temperature K-100 (MAX)	Pressure K-100	Pressure K-100 (MAX)
0	2020-12-31 23:59:59.705000	1.190	1	174	450	2108	2500
1	2021-01-01 00:59:59.705000	1.313	1	156	450	2101	2500
2	2021-01-01 01:59:59.705000	1.404	1	144	450	2103	2500
3	2021-01-01 02:59:59.705000	1.496	1	144	450	2108	2500
4	2021-01-01 03:59:59.705000	1.221	1	163	450	2100	2500

Рис. 3. Параметры работы диэтанайзера в период с 01.01.2020 по 01.08.2024

- Temperature - представляет собой измерения температуры окружающей среды.
- Season - кодировка сезонов.
- Temperature K-100 и Pressure K-100 - представляют собой нормализованные значения температуры и давления установки в момент времени (см. рис. 4-5).
- Temperature K-100 (MAX) и Pressure K-100 (MAX) - представляют собой критические параметры температуры и давления диэтанайзера.



Рис. 4. Температурный график диэтанайзера на период с 01.01.2020 по 01.08.2024



Рис. 5. График давления в диэтанайзере на период с 01.01.2020 по 01.08.2024

Перед использованием методов прогнозирования была проведена проверка на наличие пропущенных значений, дубликатов или аномалий. Было произведено приведение временных меток к стандартному формату даты и времени, а также преобразование числовых значений в соответствующие типы данных.

На основе обработанных данных было сформировано и обучено три прогнозные модели, которые описывают температуру и давление в диэтанайзере.

В табл. 3 представлена оценка качества прогнозных моделей на основе расчета средней квадратичной ошибки (MSE).

Таблица 3

Оценка качества моделей

Линейная регрессия	LSTM	ARIMA
21,35	12,32	11,97

Результаты проведенного эксперимента

В результате проведенного эксперимента была проведена оценка качества прогнозных моделей. Средняя квадратичная ошибка (MSE) модели обученной с применением линейной регрессии составила 21,35. Этот метод продемонстрировал свою простоту и эффективность

в задачах, где зависимости между переменными можно описать линейной моделью. Однако, учитывая сложность и нелинейность реальных технологических процессов, линейная регрессия может не всегда обеспечивать необходимую точность.

Модель с использованием LSTM показала более высокую точность, средняя квадратичная ошибка составила 12,32. Это подтверждает эффективность использования рекуррентных нейронных сетей для работы с временными рядами, где важен контекст и долговременные зависимости. LSTM продемонстрировала способность учитывать последовательность данных, что является критически важным для прогнозирования в технологических процессах.

Средняя квадратичная ошибка модели с использованием ARIMA, составила 11,97. Этот метод, основанный на анализе временных рядов, продемонстрировал свою эффективность в условиях стационарности данных.

Выводы

В последние годы наблюдается значительный рост интереса к применению методов машинного обучения в специализированных системах предназначенных для решения задач из разных отраслей промышленности [33]. В ходе выполнения данной работы была проведена всесторонняя оценка применения методов машинного обучения и статистического анализа для прогнозирования технологических процессов на основе временных рядов. Основное внимание было уделено анализу данных, а также трем методам: линейной регрессии, рекуррентным нейронным сетям долгой краткосрочной памяти (LSTM) и авторегрессионной интегрированной модели скользящего среднего (ARIMA).

Сравнительный анализ качества прогнозирования показал, что методы ARIMA и LSTM обеспечивают более высокую точность по сравнению с линейной регрессией. Это подчеркивает важность выбора подходящего метода в зависимости от специфики задачи и структуры данных. Линейная регрессия может быть полезна для предварительного анализа и в случаях, когда данные имеют линейные зависимости. Однако для более сложных и динамичных процессов предпочтительнее использовать LSTM или ARIMA, которые способны учитывать нелинейные зависимости и временные характеристики данных.

Литература

1. Шмелева А.С., Сулоева С.Б., Ростова О.В. Методы и инструменты гибкого управления цифровыми инновационными проектами: монография. – СПб: Политех-Пресс, 2023. – 240 с.
2. Анисимов В.Г. Анализ и оценивание эффективности инвестиционных проектов в условиях неопределенности / В.Г. Анисимов [и др.].- Москва: Военная академия Генерального штаба Вооруженных сил Российской Федерации; 2006. 288 с. EDN: SWBIZP.
3. Ильин И.В. Математические методы и инструментальные средства оценивания эффективности инвестиций в инновационные проекты / И.В. Ильин [и др.]. - Санкт-Петербург, 2018.- 289 с. EDN: XMMDTV.
4. Анисимов В.Г. Стратегическое управление инновационной деятельностью: анализ, планирование, моделирование, принятия решений, организация, оценка / В.Г. Анисимов [и др.].- Санкт-Петербург, 2017.- 312 с. EDN: ZCXSIN.
5. Анисифоров А.Б., Ростова О.В., Балабнева О.А. Основы цифровой трансформации бизнеса: учеб. пособие. – СПб: Политех-Пресс, 2023. – 96 с.
6. Системы имитационного моделирования: выбираем подходящую / [Электронный ресурс]. URL: <https://habr.com/ru/companies/lanit/articles/351870> / (дата обращения: 05. 01. 2025).
7. Широкова С.В., Ростова О.В., Болсуновская М.В., Дмитриева Л.А., Алматаев Т.О.

Аудит информационной безопасности производственной компании // Информационные и управляющие системы. – 2023. – № 1 (122). – С. 41-50.

8. Сауренко Т.Н. Модели оценки эколого-экономических последствий техногенных аварий на промышленных объектах / Т.Н. Сауренко [и др.] // Экономические стратегии ЕАЭС: проблемы и инновации: сборник материалов IV Международной научно-практической конференции.- Москва, 2021. С. 126-140. EDN: DLKSHN.

9. Сауренко Т.Н. Математические модели прогнозирования экологической угрозы техногенных аварий и катастроф в составе интегрированных систем безопасности региона / Т.Н. Сауренко [и др.] // Технологии гражданской безопасности. 2019. Т. 16. № 3 (61). С. 62-67. EDN: DUUIRX. DOI: 10.54234/CST.19968493.2019.16.3.61.11.62.

10. Зегжда П.Д. Методический подход к построению моделей прогнозирования показателей свойств систем информационной безопасности / П.Д. Зегжда [и др.] // Проблемы информационной безопасности. Компьютерные системы. 2019. № 4. С. 45-49. EDN: QLDDQ.

11. Анисимов В.Г., Анисимов Е.Г., Веселко А.А., Пак А.Ю. Оценка эффективности технологических процессов на предприятиях машиностроительной отрасли экономики // Журнал технических исследований. 2022. Т. 8. № 1. С. 30-35. EDN: GBDHEU.

12. Мальков М. В., Олейник А. Г., Федоров А. М. Моделирование технологических процессов: методы и опыт. Труды Кольского научного центра РАН, – 2010, т.13, №4. – С. 1-9.

13. Компьютерное моделирование технологических процессов / [Электронный ресурс]. URL: <http://tstu-isman.tstu.ru/pdf/lecture3.pdf> / (дата обращения: 05. 01. 2025).

14. Ростова О.В., Широкова С.В., Усиков Р.Ф. Управление системами информационно-технологической поддержки на предприятии по производству сложных технических комплексов // Вопросы оборонной техники. Серия 16: Технические средства противодействия терроризму. – 2020. – № 3-4 (141-142). – С. 9-18.

15. Тебекин А.В. Способ формирования комплексных показателей качества инновационных проектов и программ / А.В. Тебекин [и др.] // Журнал исследований по управлению. 2018. Т. 4. № 11. С. 30-38. EDN: YQGWDB.

16. Анисимов В.Г., Анисимов Е.Г., Лихачева О.А. Модель для оценивания влияния распределения ресурсов на качество образовательного процесса // Вестник Российской таможенной академии. 2012. № 4. С. 060-066. EDN: PJBTZP.

17. Анисимов В.Г., Лихачева О.А., Сергеев И.В. Оценка качества образовательного процесса с использованием математической модели // Вестник университета. 2012. № 18. С. 152-155. EDN: OGRAXA.

18. Сазыкин А.М. Прогнозирование сформированности военно-профессиональных компетенций / А.М. Сазыкин [и др.] // Известия Российской академии ракетных и артиллерийских наук. 2024. № 2 (132). С. 32-36. EDN: ARHNUG. DOI: 10.53816/20753608_2024_2_32.

19. Анисимов В.Г., Анисимов Е.Г., Босов Д.Б. Математические модели и методы управления инновационными проектами.- Москва, 2009. 188 с. EDN: TMDMSP.

20. Тебекин А.В. Модель прогноза стоимости и сроков модернизации промышленных предприятий / А.В. Тебекин [и др.] // Журнал исследований по управлению. 2019. Т. 5. № 3. С. 31-37. EDN: XBWMXL.

21. Авдеев М.М. Информационно-статистические методы в управлении микроэкономическими системами / М.М. Авдеев [и др.]. - Санкт-Петербург; Тула. 2001. 139 с. EDN: TMDNNJ.

22. Виды и типы машинного обучения / [Электронный ресурс]. URL: <https://sky.pro/wiki/python/vidy-i-tipy-mashinnogo-obucheniya> (дата обращения: 25. 01. 2025).
23. Ведерников Ю.В. Модели и алгоритмы интеллектуализации автоматизированного управления диверсификацией деятельности промышленного предприятия / Ю.В. Ведерников, А.Ю. Гарькушев [и др.] // Вопросы оборонной техники. Серия 16: Технические средства противодействия терроризму. 2014. № 5-6 (71-72). С. 61-72. EDN: SFKMTZ.
24. Скороход А. В. Обзор алгоритмов с частичным привлечением учителя. – Петрозаводск: МЦНП «Новая наука», 2021. – С. 239-243.
25. Линейная регрессия / [Электронный ресурс] // <https://habr.com/ru/articles/804135/> (дата обращения: 06. 01. 2025).
26. Рекуррентная нейронная сеть (RNN): виды, обучение, примеры / [Электронный ресурс]. URL: <https://neurohive.io/ru/osnovy-data-science/rekurrentnye-nejronnye-seti> (дата обращения: 06. 01. 2025).
27. Трегуб А. В., Трегуб И. В. Методика построения модели ARIMA для прогнозирования динамики временных рядов // Лесной вестник. – 2011. – № 5. – С. 179-183.
28. Прогнозирование временных рядов методом ARIMA / [Электронный ресурс]. URL: https://elar.urfu.ru/bitstream/10995/52487/1/978-5-9908685-0-2_2017_72.pdf (дата обращения: 22. 01. 2025).
29. Agbessi A. P., Salami A. A., Agbosse K. S., Birregah B. Peak Electrical Energy Consumption Prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU [Электронный ресурс]. URL: <https://www.mdpi.com/1996-1073/16/12/4739> (дата обращения: 06. 01. 2025).
30. Газофракционирующая установка (ГФУ) / [Электронный ресурс]. URL: <https://neftegaz.ru/tech-library/neftekhimiya/142166-gazofraktsioniruyushchaya-ustanovka-gfu/> (дата обращения: 16. 01. 2025).
31. Шмелева А.С., Сулоева С.Б., Ростова О.В. Информационная поддержка управления инновационно-инвестиционной деятельностью предприятия нефтегазовой отрасли // Журнал исследований по управлению. – 2021. – Т. 7. – № 6. – С. 57-67.
32. Моделирование технологических процессов / [Электронный ресурс]. URL: <https://ntik.ru/services/digital/solutions/proxima> (дата обращения: 14. 01. 2025).
33. Ragas A.A.M.A., Chupin A.L., Bolsunovskaya M. V., Shirokova S. V., Senotrusova, S. V. Accelerating Sustainable and Economic Development via Scientific Project Risk Management Model of Industrial Facilities // Sustainability (Switzerland), 2023.