

УДК 681.5

DOI 10.54708/2658-5014-SIIT-2024-no4-p69

EDN BJQURV

РАЗРАБОТКА НЕЙРОННОЙ СЕТИ ДЛЯ УПРАВЛЕНИЯ ПРОЦЕССОМ ПИРОЛИЗА ДИХЛОРЕТАНА С ЦЕЛЮ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ ПРОЦЕССА

Е. А. МУРАВЬЕВА • А. И. НИКОЛАЕВА

Аннотация. В настоящее время большая часть химических предприятий сталкиваются с постоянно растущими проблемами из-за увеличивающейся конкуренции, строгих экологических стандартов и постоянного давления на снижение затрат и повышение производительности. В связи с новыми требованиями к улучшению производственных процессов химическая промышленность уделяет особое внимание разработке и внедрению эффективных методов управления. В данных условиях для предприятий химической отрасли очень важно оптимизировать технологические процессы. Методы машинного обучения и использование нейронных сетей для оптимизации параметров процессов являются двумя примерами стремительного развития инструментов искусственного интеллекта в последние десятилетия. Данные инновационные методы позволяют системам автоматически корректировать свои параметры на основе полученных данных, что обеспечивает более надежное и эффективное управление в постоянно меняющихся условиях. Цель данной работы – разработка нейронной сети для управления процессом пиролиза дихлорэтана, направленная на повышение эффективности и оптимизацию процесса. Применение методов машинного обучения позволяет улучшить параметры процесса, сократить время реакции и увеличить выход винилхлорида. Такой подход способствует повышению эффективности производства за счет использования передовых технологий.

Ключевые слова: нейронные сети; машинное обучение; пиролиз дихлорэтана; автоматизация; машинное обучение; оптимизация; TensorFlow, Keras; промышленная автоматизация; искусственный интеллект.

ВВЕДЕНИЕ

В результате стремительного развития информационных технологий и доступности передовых технических решений интеллектуальные системы управления становятся все более актуальными для оптимизации и совершенствования процессов, особенно – при производстве химических продуктов. Процесс пиролиза дихлорэтана, применяемый для производства винилхлорида, не является исключением. Данный процесс включает в себя множество параметров, которые необходимо настроить и контролировать для обеспечения оптимальной производительности и качества продукции. Существующие ПИД-регуляторы, долгое время используемые в управлении производственными процессами, ограничены в работе с нелинейными объектами, адаптации к динамике системы и решении задач оптимизации, что может снижать производительность системы управления [1, 2]. В процессе пиролиза дихлорэтана, где параметры могут меняться со временем, ПИД-регуляторы, ориентированные на определенные значения коэффициентов, могут терять эффективность, приводя к потере стабильности и отклонениям от заданных значений [3, 4].

Научная новизна исследования заключается в разработке специализированной нейронной сети для управления процессом пиролиза дихлорэтана, адаптированной к специфике данного производственного процесса. В рамках работы применяются передовые методы машинного обучения для анализа и оптимизации параметров процесса пиролиза дихлорэтана. Интеграция разработанной нейронной сети в систему управления производственным процессом позволяет значительно повысить его эффективность и стабильность. Комплексное тестирование и оценка эффективности нейронной сети на реальных данных подтверждают ее практическую применимость и улучшение производственных показателей. Разработка позволяет оптимизировать параметры процесса, уменьшить время реакции и повысить выход конечного продукта – винилхлорида. Данный подход представляет собой значительный шаг в направлении повышения эффективности производственных процессов за счет применения

передовых методов искусственного интеллекта. Разработанная система позволяет не только улучшить стабильность и точность управления процессом пиролиза, но и создать основу для дальнейших инноваций в области автоматизации и оптимизации химических производств.

Практическая значимость исследования заключается в создании нейронной сети, способной эффективно управлять процессом пиролиза дихлорэтана. Внедрение данной разработки в производственный процесс позволяет оптимизировать параметры пиролиза, что ведет к снижению времени реакции и увеличению выхода конечного продукта – винилхлорида, что способствует повышению общей эффективности производства, снижению операционных затрат и улучшению качества продукции. Разработанная система управления на основе нейронной сети может быть адаптирована и применена в других химических процессах, требующих оптимизации параметров.

Таким образом, данное исследование представляет собой инновационный метод. Использование нейронной сети для автоматической коррекции параметров процесса позволяет значительно улучшить управление производственным процессом, минимизировать потери и повысить общую эффективность производства винилхлорида.

ИДЕНТИФИКАЦИЯ И КЛАССИФИКАЦИЯ РАБОЧИХ ПАРАМЕТРОВ

В связи с необходимостью улучшения системы управления для технологического процесса пиролиза дихлорэтана и отсутствием достаточного исследования в данной области разработка интеллектуальной системы управления на основе нейронных сетей с использованием библиотеки машинного обучения TensorFlow представляет собой актуальный подход [5, 6]. Процесс пиролиза дихлорэтана (ДХЭ) представляет собой сложный химический процесс, при котором происходит термическое разложение дихлорэтана для получения винилхлорида [7, 8]. Для эффективного управления данным процессом необходимо контролировать множество факторов, которые влияют на эффективность процесса пиролиза дихлорэтана, что является критически важным аспектом для достижения высокой производительности и качества конечного продукта. Основные параметры процесса пиролиза дихлорэтана можно классифицировать следующим образом: температурные параметры: в процессе пиролиза дихлорэтана точное соблюдение температурных режимов играет решающую роль в эффективности и качестве производственного процесса; давленометрические параметры: давление в различных точках системы контролируется для оптимизации расхода сырья и обеспечения стабильности процесса; химические и компонентные параметры; процессные параметры; параметры качества; временные параметры; количественные параметры.

Увеличение выхода винилхлорида может быть достигнуто за счет оптимизации всех параметров, рассмотренных выше, таких как температура, давление, скорость подачи и другие. Каждый из этих параметров является ключевым для успешного осуществления процесса пиролиза дихлорэтана, влияя на его эффективность, экономичность и экологическую безопасность.

ПРЕДВАРИТЕЛЬНАЯ ОБРАБОТКА ДАННЫХ

Предварительная обработка данных играет ключевую роль в разработке системы управления на основе нейронных сетей для оптимизации процесса пиролиза дихлорэтана. Данный этап является важным подготовительным этапом перед изучением модели машинного обучения. Целью предварительной обработки данных являются подготовка и очистка исходных данных для обеспечения их корректности, согласованности и пригодности для дальнейшего анализа и использования в модели [9, 10].

Этап 1. Загрузка данных из файла Excel. Загрузка данных из файла Excel является первым и важным этапом предварительной обработки данных для разработки системы управления на основе нейронной сети. Данный шаг обеспечивает доступ к исходным данным, необходимым для последующего анализа и обучения модели.

Этап 2. После загрузки данных из файла Excel следующим важным этапом предварительной обработки данных являются удаление специальных символов и преобразование значений в числовой формат. Данный этап необходим для того, чтобы обеспечить корректное выполнение математических операций и обучение нейронной сети.

Этап 3. Следующий этап – разделение данных на входные признаки (features) и целевые переменные (targets) из «DataFrame». После удаления строк с пропущенными значениями необходимо разделить данные на входные признаки (features) и целевые переменные (targets). Данный шаг является важным, так как входные признаки будут использоваться для предсказания целевых переменных в процессе обучения нейронной сети [11–14].



Рис. 1 Блок-схема обучения модели нейронной сети.

Этап 4. Далее – масштабирование признаков, являющееся важным этапом предварительной обработки данных для машинного обучения, особенно – для нейронных сетей. Масштабирование приводит все признаки к одному диапазону, что помогает алгоритму быстрее и эффективнее находить оптимальные параметры.

Этап 5. Следующий этап – разделение данных на обучающий и тестовый наборы для оценки производительности модели машинного обучения. Разделение данных на обучающий и тестовый наборы является важным шагом в процессе создания и оценки модели машинного обучения. Обучающий набор используется для тренировки модели, а тестовый набор – для оценки её производительности на новых, невиданных данных, что позволяет проверить, насколько хорошо модель может обобщать на новые данные [15, 16].

ОПРЕДЕЛЕНИЕ АРХИТЕКТУРЫ МОДЕЛИ НЕЙРОННОЙ СЕТИ

Реализация интеграции интеллектуальной системы управления, работающей на основе нейронных сетей, с программной библиотекой машинного обучения TensorFlow в процесс пиролиза дихлорэтана требует выполнения нескольких этапов.

Определение архитектуры модели нейронной сети является критическим этапом проектирования системы машинного обучения. На данном этапе был использован фреймворк «TensorFlow» с высокоуровневым API «Keras» для создания и обучения модели. «TensorFlow» предоставляет мощные инструменты для вычислений и оптимизации моделей на различных уровнях абстракции, а «Keras» упрощает процесс создания нейронных сетей благодаря интуитивно понятному интерфейсу и модульной структуре [17–20].

Архитектура модели включает несколько слоев «Dense» с активациями «ReLU» и «dropout» для предотвращения переобучения, что позволяет модели эффективно извлекать признаки из входных данных и обучаться на них. Использование оптимизатора «Adam» и функции потерь «Mean Squared Error» (MSE) обеспечивает эффективный процесс обучения, а также метрика «MAE» (Mean Absolute Error) используется для оценки качества модели.

Таким образом, выбор «TensorFlow» и «Keras» для определения архитектуры нейронной сети обусловлен их удобством, производительностью и гибкостью, что делает их предпочтительным выбором для разработки современных систем машинного обучения и исследовательских проектов.

ОБУЧЕНИЕ МОДЕЛИ НЕЙРОННОЙ СЕТИ

После компиляции модели следующий шаг – обучение модели на подготовленных данных. Блок-схема обучения модели нейронной сети представлена на рис. 1.

1. Параметры обучения. Обучение модели включает в себя настройку нескольких ключевых параметров, которые определяют, как модель будет тренироваться на данных. Основными параметрами являются количество эпох, размер пакета и валидационное разделение.

2. Оценка производительности модели на независимом наборе данных. Данный этап необходим для проверки того, насколько хорошо модель может обобщать свои предсказания на новые, ранее невиданные данные.

3. Вычисление потерь и вывод результата. Функция потерь является ключевым показателем качества модели, который показывает, насколько хорошо модель справляется с задачей предсказания.

4. После оценки модели производится предсказание значений на тестовом наборе данных. Метод «predict» используется для генерации предсказанных значений на основе обученной модели.

5. Проверка результатов: удовлетворяют ли условиям предсказанные значения. Для проверки качества предсказаний проводится анализ того, насколько предсказанные значения соответствуют ожидаемым значениям.

Обучение модели является одним из ключевых этапов, который позволяет модели настраивать свои параметры для оптимального предсказания на основе входных данных.

Таким образом, этап обучения модели нейронной сети включает в себя выбор параметров обучения, оценку производительности модели, вычисление потерь и предсказание значений на тестовом наборе данных. Каждый этап играет важную роль в создании и оптимизации модели, обеспечивая её высокую точность и способность к обобщению на новые данные. Использование многопоточности позволяет сохранить отзывчивость интерфейса и сделать процесс обучения более удобным для пользователя [21, 22].

ОПИСАНИЕ ПРОГРАММЫ И ЕЕ РЕЗУЛЬТАТЫ

Создание программы было выполнено в кроссплатформенной интегрированной среде разработки PyCharm для языка программирования Python, разработанной компанией JetBrains на основе IntelliJ IDEA, предоставляющей пользователю комплекс средств для написания кода и визуальный отладчик [23, 24].

Основной фокус при разработке системы управления на основе нейронной сети для оптимизации параметров направлен на использование библиотеки «TensorFlow» и её высокоуровневого интерфейса «Keras», что является отличным выбором по ряду причин. Данные библиотеки предлагают мощные инструменты для разработки и обучения нейронных сетей, что делает их идеальными для задач, связанных с обработкой данных и оптимизацией процессов. «Keras» предоставляет удобный и интуитивно понятный интерфейс для построения и обучения нейронных сетей. Синтаксис «Keras» позволяет быстро создавать сложные модели, используя минимальное количество кода. В коде программы при разработке используются такие функции «Keras», как «Sequential», «Dense» и «Dropout», что позволяет легко настраивать архитектуру нейронной сети.

«TensorFlow» предоставляет низкоуровневые API для более детального контроля и оптимизации моделей, что позволяет решать сложные задачи, которые могут потребовать нестандартных подходов и решений. «TensorFlow» также поддерживает распределенное обучение, что позволяет ускорить процесс обучения на больших наборах данных [25, 26].

В совокупности «TensorFlow» и «Keras» включают множество встроенных функций для предварительной обработки данных, таких как нормализация и разделение на обучающие и тестовые наборы. В работе реализация выполнена с помощью «MinMaxScaler» и «train_test_split». Метрики и функции потерь в «Keras», такие как «mean_squared_error» и «mae», также помогают оценивать и отслеживать качество моделей. В том числе «TensorFlow» и «Keras» имеют большое сообщество пользователей и разработчиков, что делает их отличным выбором для любых проектов – подробная документация и множество обучающих материалов позволяют быстро освоить данные библиотеки и эффективно использовать их.

Создание и компиляция модели происходит с использованием современных архитектур нейронных сетей. Обучение модели осуществляется в отдельном потоке, чтобы избежать блокировки интерфейса и позволить пользователю взаимодействовать с системой во время выполнения длительных операций. Процесс обучения сопровождается логированием прогресса, включая значения функции потерь на обучающем и валидационном наборах данных, что позволяет отслеживать эффективность обучения. После оптимизации параметров системы для пиролиза дихлорэтана были получены следующие результаты по сравнению с исходными данными:

1. Целевым параметром является время реакции на 1 тонну подаваемого ДХЭ:
 - начальное значение: 256.67 часа;
 - оптимизированное значение: 127.76 часа;

- изменение: время реакции сократилось на 128.91 часа, или на $\approx 50\%$.
- 2. Целевым параметром является выход винилхлорида на 1 тонну подаваемого ДХЭ:
 - начальная стоимость: 30 тонн;
 - оптимизированное значение: 77.54 тонны;
 - изменение: выход винилхлорида увеличился на 47.54 тонны, или на 158%.

При использовании алгоритмов оптимизации и моделирования система скорректировала ключевые параметры процесса, что позволило сократить время реакции пиролиза и увеличить выход винилхлорида. Данные изменения были направлены на повышение производительности процесса, уменьшение времени производства винилхлорида и увеличение выхода продукции на единицу входного материала. Оптимизация параметров значительно повысила эффективность химического производства, демонстрируя эффективность используемого подхода.

Для наглядности работы модели предусмотрен график функции потерь обучения и валидации (рис. 2). Данный график иллюстрирует динамику функции потерь для обучения и валидации модели нейронной сети, обученной для управления процессом пиролиза дихлорэтана. Параметры, которые отслеживаются на графике, включают потери на обучающем наборе данных и потери на валидационном наборе данных, что позволяет оценить, насколько хорошо модель обучается и обобщает результаты на новых данных.

График функции потерь для обучения и валидации отображает одну величину ошибки (или потерь), которая вычисляется на основе предсказаний модели по всем ключевым (входным) параметрам. В машинном обучении цель состоит в том, чтобы минимизировать эту разницу, улучшая точность предсказаний.

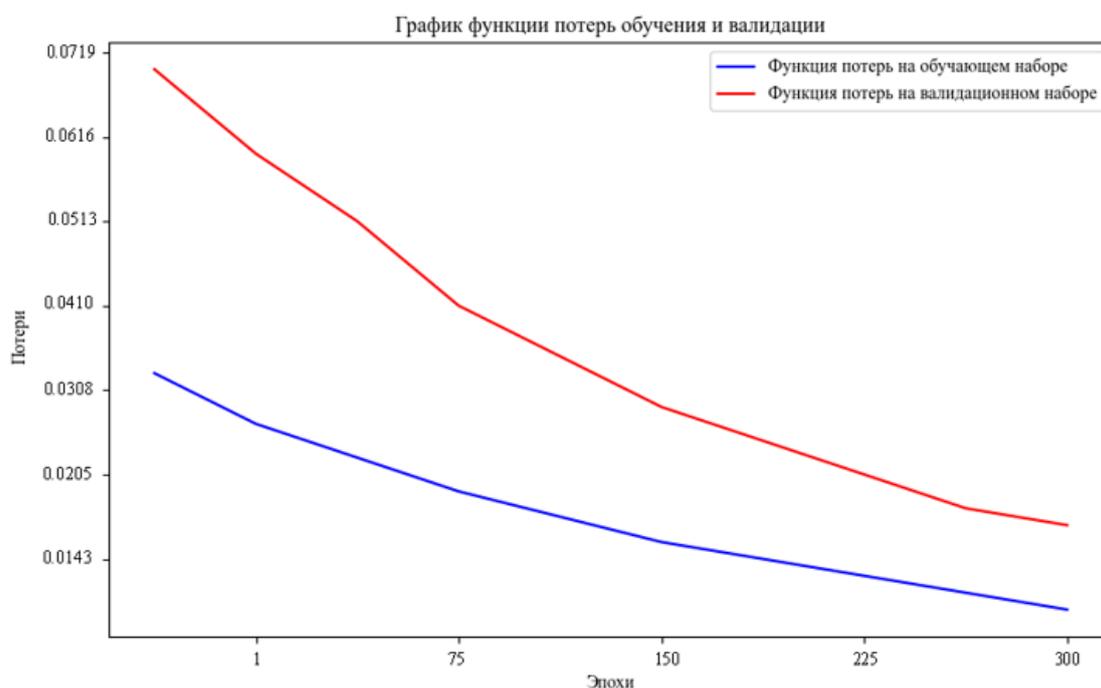


Рис. 2 График функции потерь обучения и валидации.

Функция потерь вычисляет разницу между предсказанными моделью и реальными значениями целевых переменных, чтобы оценить, насколько хорошо модель обучается. На каждом шаге обучения модель делает прогноз для каждого целевого параметра, функция потерь затем сравнивает данные прогнозы с фактическими значениями, которые были получены из данных. Разница между предсказанными и реальными значениями (ошибка) измеряется с помощью определенной функции потерь – средней квадратичной ошибки (MSE) и средней абсолютной ошибки (MAE). Данные функции суммируют индивидуальные ошибки по всем обучающим примерам, создавая общую величину потерь.

Таким образом, один график показывает общую ошибку модели на обучающем и валидационном наборах данных, агрегируя результаты по всем входным параметрам, чтобы оценить, насколько хорошо модель обобщает информацию и делает прогнозы.

Из графика видно, что начальные значения потерь на валидации выше, чем на обучении, что может указывать на начальное переобучение модели. Однако с увеличением числа эпох потери как на обучении, так и на валидации снижаются. После определенного числа эпох (после 50–100 эпох) потери на обучении и валидации становятся близкими друг к другу, что может свидетельствовать о том, что модель находится в зоне хорошего обобщения. Установлено, что наилучшее качество достигается при значениях потерь примерно 0.01 на обучающем наборе и примерно 0.02 на валидационном наборе к концу обучения на 300 эпохах.

Данный график помогает визуализировать процесс обучения модели и оценить её эффективность и способность к обобщению на новых данных.

ЗАКЛЮЧЕНИЕ

Разработка нейронной сети для оптимизации параметров пиролиза дихлорэтана позволила увеличить выход винилхлорида и сократить время реакции. В результате применения алгоритмов оптимизации и моделирования на основе нейронных сетей были достигнуты значительные улучшения производственных показателей.

Исходное время реакции на 1 тонну подаваемого ДХЭ удалось сократить с 256.67 часа до 127.76 часа, что составляет $\approx 50\%$ уменьшения времени реакции, что позволило значительно повысить эффективность процесса пиролиза, ускорив производственные циклы и снизив затраты на производство. Также было достигнуто увеличение выхода винилхлорида с 30 тонн до 77.54 тонны на 1 тонну подаваемого ДХЭ, что соответствует повышению выхода продукции на $\approx 158\%$, что является значительным улучшением экономической эффективности производства.

Анализ результатов обучения нейронной сети показал, что начальные потери на валидации превышали потери на обучении, что могло свидетельствовать о начальном переобучении модели. Однако благодаря правильному выбору архитектуры нейронной сети и оптимальных параметров обучения потери на обучающем и валидационном наборах стали снижаться по мере увеличения числа эпох – это указывает на то, что модель достигла зоны хорошего обобщения и демонстрирует способность эффективно предсказывать оптимальные параметры процесса пиролиза.

Таким образом, использование нейронных сетей для оптимизации процессов химического производства является перспективным направлением развития, позволяющим значительно улучшить производственные показатели, снизить затраты и повысить конкурентоспособность продукции на рынке.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Muravyova E. A., Gabitov R. F. Development of an intelligent complex for parallel operation of steam boilers // Journal of physics: conference series. Materials of the II International Scientific Conference on Metrological Support of Innovative Technologies. 2021. P. 22047.
2. Muravyova E. A., Gabitov R. F., and Sabanov P. A. Separation process control system in the cement production facility // Journal of Physics: conference series. Materials of the II International Scientific Conference on Metrological Support of Innovative Technologies. 2021. P. 22050.
3. Астапов Р. Л., Мухамадеева Р. М. Автоматизация подбора параметров машинного обучения и обучение модели машинного обучения // Актуальные научные исследования в современном мире. 2021. № 5–2 (73). С. 34–37. [[R. L. Astapov, R. M. Mukhamadeeva. "Automation of machine learning parameter selection and model training" // Aktualnye Nauchnye Issledovaniya v Sovremennom Mire, No. 5-2 (73), pp. 34-37, 2021. (In Russian).]]
4. Dubovitski A. A., Klimentova E. A., Rogov M. A. Applicability of machine learning models using a neural network for predicting the parameters of the development of food markets // Journal of Process Management and New Technologies. 2022. Vol. 10. No. 3–4. Pp. 93–105.
5. Osipov A. V., Pleshakova E. S., Bykov A. A., Kuzichkin O. R., Surzhik D. I., Suvorov S. V., Gataullin S. T. Machine learning methods based on geophysical monitoring data in low time delay mode for drilling optimization // IEEE Access. 2023. Pp. 1–11.
6. Николаева А. И. Разработка автоматизированной системы управления процессом пиролиза дихлорэтана в цехе №29 акционерного общества «Башкирская содовая компания» // Наука и инновационные технологии. 2023. № 2–27. С. 197–201. [[A. I. Nikolaeva. "Development of an automated control system for the pyrolysis process of dichloroethane in workshop No. 29 of Bashkir Soda Company" // Nauka i Innovacionnyye Tekhnologii, no. 2-27, pp. 197-201, 2023. (In Russian).]]
7. Kitov V. V., Mishustina M. V., Ustyuzhanin A. O. Time series prediction survey of statistical, machine learning and deep learning methods: historical aspects // Voprosy istorii. 2022. No. 4–2. Pp. 201–218.
8. Сапрыкин Д. А., Кравцова Е. Ю. Алгоритмы машинного обучения в классификации и ее задачи в обучении моделей // Моя профессиональная карьера. 2022. Т. 2. № 43. С. 232–237. [[D. A. Saprykin, E. Yu. Kravtsova. "Machine learning algorithms in classification and their tasks in model training" // Moya Professionalnaya Kariera, vol. 2, no. 43, pp. 232-237, 2022. (In Russian).]]

9. Городничев Д. Ю. Машинное обучение и глубокое обучение // Современные проблемы лингвистики и методики преподавания русского языка в вузе и школе. 2022. № 38. С. 278–281. [[D. Yu. Gorodnichev. "Machine learning and deep learning" // *Sovremennye Problemy Lingvistiki i Metodiki Prepodavaniya Russkogo Yazyka v Vuze i Shkole*, no. 38, pp. 278-281, 2022. (In Russian).]]
10. Жуланов В. Н. Применение градиентного спуска для обучения модели машинного обучения // Инновационные технологии: теория, инструменты, практика. 2021. Т. 1. С. 16–21. [[V. N. Zhulanov. "Application of gradient descent for machine learning model training," in *Innovatsionnye Tekhnologii: Teoriya, Instrumenty, Praktika*, vol. 1, pp. 16-21, 2021. (In Russian).]]
11. Бубченко Е. И. Сравнение эффективности нейросетей прямого распространения и рекуррентных нейросетей // Научно-технический вестник Поволжья. 2023. № 11. С. 414–416. [[E. I. Bubchenko. "Comparison of the efficiency of feedforward and recurrent neural networks" // *Nauchno-Tekhnicheskii Vestnik Povolzh'ya*, no. 11, pp. 414-416, 2023. (In Russian).]]
12. Isaeva A. S., Denisenko M. A., Kovalev A. V. Neural network application to road surface type identification // *Computational Technologies*. 2023. Vol. 28, No. 2. Pp. 19–26.
13. Zhu W., Zhan Y., & Romagnoli J. A deep learning approach on industrial pyrolysis reactor monitoring // *Chemical Engineering Transactions*. 2019. No. 74. Pp. 691–696.
14. Garg A., & Dutta P. Applications of machine learning in pyrolysis: a comprehensive review // *Journal of Energy Chemistry*. 2022. No. 64. Pp. 127–140.
15. Попов Е. А., Стариков М. А., Невкин А. А. Внедрение алгоритмов машинного обучения в производственные процессы компаний нефтяной и газовой промышленности // Бурение и нефть. 2021. № 4. С. 36–40. [[E. A. Popov, M. A. Starikov, and A. A. Nevkin. "Implementation of machine learning algorithms in the production processes of oil and gas companies" // *Burenie i Neft'*, no. 4, pp. 36-40, 2021. (In Russian).]]
16. Крюков А. С. Применение искусственного интеллекта и машинного обучения в промышленности // Инженерные кадры – будущее инновационной экономики России. 2023. № 1. С. 478–480. [[A. S. Kryukov. "Application of artificial intelligence and machine learning in industry" // *Inzhenernye Kadry – Budushchee Innovatsionnoy Ekonomiki Rossii*, no. 1, pp. 478-480, 2023. (In Russian).]]
17. Кондрашов М. И., Моткин И. Д. Применение методов машинного обучения в промышленности // Студенческий. 2023. № 2–1 (214). С. 51–54. [[M. I. Kondrashov and I. D. Motkin. "Application of machine learning methods in industry" // *Studencheskiy*, no. 2-1 (214), pp. 51-54, 2023. (In Russian).]]
18. Хамитов Р. М. Перспективы интеграции методов машинного обучения в металлургическую промышленность // Экономика и предпринимательство. 2024. № 9 (170). С. 1116–1119. [[R. M. Khamitov. "Prospects for integrating machine learning methods in the metallurgical industry" // *Ekonomika i Predprinimatel'stvo*, no. 9 (170), pp. 1116-1119, 2024. (In Russian).]]
19. Карпович А. В. Машинное обучение и его роль в развитии промышленности // Инновационная наука. 2023. № 9–1. С. 9–12. [[A. V. Karpovich. "Machine learning and its role in industrial development" // *Innovatsionnaya Nauka*, no. 9-1, pp. 9-12, 2023. (In Russian).]]
20. Китова О. В., Савинова В. М., Иксанов В. Р. Сравнительный анализ методов машинного обучения для прогнозирования показателей промышленности РФ // Вопросы истории. 2022. № 9–12. С. 248–262. [[O. V. Kitova, V. M. Savinova, and V. R. Iksanov, "Comparative analysis of machine learning methods for predicting the performance of Russian industry" // *Voprosy Istorii*, no. 9-12, pp. 248-262, 2022. (In Russian).]]
21. Абдрафикова Ф. Ф., Муравьева Е. А. Технология FMEA-анализа процесса добычи нефти // СИИТ. 2021. Т. 3. № 2(6). С. 50–57. EDN HUPBIQ. [[Abdrfikova F. F., Muravyova E. A. "FMEA analysis technology for the oil production process" // *SIIT*. 2021. Vol. 3, No. 2(6), pp. 50-57. EDN HUPBIQ. (In Russian).]]
22. Муравьева Е. А., Шокуров С. А. Использование нечеткого регулятора для прогнозирования состояния объекта управления // СИИТ. 2019. Т. 1. № 2(2). С. 42–50. EDN LYWNTM. [[Muravyova E. A., Shokurov S. A. "Using a fuzzy controller to predict the state of a control object" // *SIIT*. 2019. Vol. 1, No. 2(2), pp. 42-50. EDN LYWNTM. (In Russian).]]
23. Веревкин А. П., Муртазин Т. М. Моделирование производственных процессов на основе когнитивной информации и временных рядов // СИИТ. 2022. Т. 4. № 1(8). С. 12–19. EDN QPTPES. [[Verevkin A. P., Murtazin T. M. "Modeling of production processes based on cognitive information and time series" // *SIIT*. 2022. Vol. 4, No. 1(8), pp. 12-19. EDN QPTPES. (In Russian).]]
24. Гвоздев В. Е., Давлиева А. С. Оценка функциональной безопасности аппаратно-программных комплексов на основе математико-статистических методов // СИИТ. 2023. Т. 5. № 2(11). С. 33–40. EDN VLLUZS. [[Gvozdev V. E., Davlieva A. S. "Assessment of the functional safety of hardware and software complexes based on mathematical and statistical methods" // *SIIT*. 2023. Vol. 5, No. 2(11), pp. 33-40. EDN VLLUZS. (In Russian).]]
25. Брекоткин В. Е., Брекоткина Е. С., Павлов А. С., Павлов С. В. Информационная технология подбора компонентов сложных технических систем на основе интеллектуального анализа их желаемых и фактических характеристик из распределенных баз данных // СИИТ. 2022. Т. 4. № 2(9). С. 13–23. EDN XGTHJD. [[Brekotkin V. E., Brekotkina E. S., Pavlov A. S., Pavlov S. V. "Information technology for selecting components of complex technical systems based on intelligent analysis of their desired and actual characteristics from distributed databases" // *SIIT*. 2022. Vol. 4, No. 2(9), pp. 13-23. EDN XGTHJD. (In Russian).]]
26. Кочергин Г. А., Муратов И. Н., Куприянов М. А. Оценка и картографирование экологических рисков в информационной системе нефтедобывающего региона // СИИТ. 2021. Т. 3. № 3(7). С. 65–71. EDN HIFKRZ. [[Kochergin G. A., Muratov I. N., Kupriyanov M. A. "Assessment and mapping of environmental risks in the information system of an oil-producing region" // *SIIT*. 2021. Vol. 3, No. 3(7), pp. 65-71. EDN HIFKRZ. (In Russian).]]

МЕТАДАННЫЕ / METADATA

Title: Development of a neural network for controlling the pyrolysis process of dichloroethane to improve process efficiency.

Abstract: Currently, most chemical enterprises face steadily increasing challenges due to increasing competition, strict environmental standards and constant pressure to reduce costs and increase productivity. Due to the new requirements for improving production processes, the chemical industry pays special attention to the development and implementation of effective management methods. In these conditions, it is very important for chemical industry enterprises to optimize technological processes. Machine learning techniques and the use of neural networks to optimize process parameters are two examples of the rapid development of artificial intelligence tools in recent decades. These innovative methods allow systems to automatically adjust their parameters based on the received data, which ensures more reliable and efficient management in constantly changing conditions. The purpose of this work is to develop a neural network for controlling the pyrolysis of dichloroethane, aimed at increasing efficiency and optimizing the process. The use of machine learning methods makes it possible to improve process parameters, reduce reaction time and increase the yield of vinyl chloride. This approach helps to increase the efficiency of production through the use of advanced technologies.

Key words: neural networks, machine learning, pyrolysis of dichloroethane, automation, machine learning, optimization, TensorFlow, Keras, industrial automation, artificial intelligence.

Язык статьи / Language: Русский / Russian.

Об авторах / About the authors:**МУРАВЬЕВА Елена Александровна**

Уфимский государственный нефтяной технический университет, Россия.

Зав. каф. автоматизированных технологических и информационных систем ин-та хим. технологий и инжиниринга в Стерлитамаке. Дипл. инж. по автоматизации технол. процессов и производств (Уфимск. гос. нефтяной техн. ун-т, 1998). Д-р техн. наук по автоматизации и управлению технол. процессами и производствами (Там же, 2013). Иссл. в обл. интелл. систем управления сл. техн. объектами и процессами.

E-mail: muraveva_ea@mail.ru

ORCID: <https://orcid.org/0000-0002-7118-5570>

НИКОЛАЕВА Анастасия Игоревна

Уфимский государственный нефтяной технический университет, Россия.

Студ. ин-та хим. технологий и инжиниринга в Стерлитамаке.

E-mail: nai.06.nai.06.nai@gmail.com

MURAVYOVA Elena Aleksandrovna

Ufa State Petroleum Technical University, Russia.

Head of the Automated Technological and Information Systems Dept, Institute of Chemical Technologies and Engineering in Sterlitamak. Dipl. Eng. for automation of technological processes and production (Ufa State Petroleum Technical University, 1998). Dr. Tech. Sci. on automation and control of technological processes and industries (ibid., 2013). Research on the development of intelligent control systems for complex technical processes.

E-mail: muraveva_ea@mail.ru

ORCID: <https://orcid.org/0000-0002-7118-5570>

NIKOLAEVA Anastasia Igorevna

Ufa State Petroleum Technical University, Russia.

Stud. of Institute of Chemical Technologies and Engineering.

E-mail: nai.06.nai.06.nai@gmail.com