

Алгоритмы интеллектуальной обработки технологической документации для контроля качества производственного процесса изготовления нанокompозитов с заданными электрофизическими свойствами

С.А. Корчагин, Д.В. Сердечный, Н.В. Беспалова

Финансовый университет при Правительстве Российской Федерации, Москва

Аннотация: В статье рассматриваются алгоритмы интеллектуальной обработки документов как ключевой инструмент для контроля качества производственного процесса изготовления нанокompозитов. Проведен анализ методов предобработки и анализа технологической документации, включая извлечение сущностей, классификацию данных и выявление аномалий. Сравнение проводится в контексте применимости данных алгоритмов к задачам обеспечения заданных электрофизических свойств конечного продукта. Рассмотрены возможности использования интеллектуальных методов для прогнозирования дефектов, оптимизации параметров синтеза и автоматизации формирования отчетности. Исследованы преимущества и недостатки применяемых подходов, а также их эффективность в различных сценариях управления качеством на производстве. Статья будет полезна специалистам в области материаловедения, инженерам-технологам, а также разработчикам систем автоматизации и исследователям, интересующимся применением искусственного интеллекта в промышленности.

Ключевые слова: машинное обучение, автоматическая обработка документов, искусственный интеллект, нанокompозиты, математическое моделирование, программный комплекс

Введение

Современное развитие материаловедения, особенно в области нанотехнологий, требует не только синтеза новых функциональных материалов, но и обеспечения строгого контроля их свойств на всех этапах производственного цикла. Нанокompозиты, обладающие заданными электрофизическими характеристиками — такими как диэлектрическая проницаемость, электропроводность, пьезоэффект или термоэлектрическая чувствительность — находят всё более широкое применение в микроэлектронике [1, 2], сенсорике [3, 4], энергетике [5, 6], адаптивных системах [7]. Однако, воспроизводимость их свойств в промышленных масштабах остаётся серьёзной научно-технической задачей, обусловленной

высокой чувствительностью наноструктур к малейшим отклонениям в технологических параметрах.

Традиционные подходы к контролю качества, основанные на ручном анализе технологической документации и выборочном физическом тестировании, оказываются недостаточными для обеспечения стабильности свойств нанокомпозитов [8]. В условиях многомерности входных параметров (температура, давление, концентрация наполнителя, скорость смешивания, время полимеризации и др.) и нелинейной зависимости выходных характеристик от них, возникает необходимость в автоматизированных методах обработки и интерпретации технологических данных.

В исследовании предлагаются алгоритмы интеллектуальной обработки технологической документации, сочетающие методы машинного обучения, семантического анализа и цифрового моделирования для выявления скрытых корреляций между технологическими режимами и конечными электрофизическими свойствами нанокомпозитов. Разработанные алгоритмы позволяют не только прогнозировать отклонения в свойствах продукции до её физического изготовления, но и рекомендовать корректировки технологических параметров в режиме реального времени, тем самым обеспечивая переход от реактивного к превентивному контролю качества.

Актуальность исследования обусловлена необходимостью повышения эффективности производства функциональных наноматериалов, сокращения брака и снижения затрат на экспериментальную оптимизацию. Представленные решения формируют основу для создания цифровых двойников производственных процессов, что соответствует современным трендам в области Industry 4.0 [8] и умного производства [9].

Алгоритмы интеллектуальной обработки технологической документации

Производство нанокompозитов с заданными электрофизическими свойствами представляет собой многостадийный процесс, включающий: подготовку исходных компонентов, диспергирование наночастиц в матрице, формование (литьё, прессование, экструзия), термообработку (отверждение, спекание, отжиг), постобработку (механическая доводка, нанесение покрытий). На каждом этапе фиксируется множество технологических параметров: температурные профили, временные интервалы, скорости сдвига, концентрации, давление, влажность, энергетические характеристики оборудования и др. Совокупность этих данных формирует технологическую документацию — как структурированную (например, табличные журналы), так и неструктурированную (протоколы операторов, замечания в отчётах, изображения микроструктур и пр.). Ключевая задача — установить причинно-следственные связи между вариациями в технологических параметрах и отклонениями в электрофизических свойствах готового материала (например, проводимостью σ , диэлектрической проницаемостью ϵ).

Алгоритм интеллектуальной обработки технологической документации состоит из 4 основных шагов:

- Шаг 1. Предобработка и нормализация данных.
- Шаг 2. Извлечение признаков и снижение размерности.
- Шаг 3. Прогнозирование и диагностика отклонений.
- Шаг 4. Генерация рекомендаций.

Алгоритм был реализован в виде комплекса программ, каждому шагу алгоритма соответствует определенный модуль, схема программного комплекса изображена на рисунке 1.




Рис. 1 – Схема программного комплекса

Рассмотрим каждый из модулей более подробно. Модуль предобработки и нормализации данных осуществляет: парсинг данных (CSV, XML, JSON, PDF-отчёты); семантический анализ неструктурированных текстов (замечания операторов, протоколы нештатных ситуаций) с использованием NLP-моделей на основе BERT-архитектуры; восстановление пропущенных значений методом k-ближайших соседей с учётом контекста технологического этапа; нормализацию параметров. Модуль извлечения признаков и снижения размерности основан на использовании метода главных компонент (PCA) и t-SNE для визуализации и сжатия пространства параметров и алгоритмов отбора признаков на основе SHAP-значений [10] для выявления наиболее значимых технологических факторов. В модуле прогнозирования и диагностики отклонений используется ансамбль моделей машинного обучения: градиентный бустинг (XGBoost, LightGBM) для точного прогнозирования количественных свойств, свёрточные нейронные сети (CNN) для анализа изображений микроструктур и корреляции с электрофизическими характеристиками, рекуррентные нейронные сети

(LSTM) для моделирования временной динамики процесса и прогнозирования накопленных отклонений. Модуль рекомендаций и обратной связи реализован с использованием LLM модели GigaChat 2 Max и технологии RAG. Модуль позволяет генерировать предупреждения о риске выхода параметров за допустимые пределы, альтернативные маршруты технологического процесса, основанные на анализе успешных аналогичных партий из архива, сохраненных в векторной базе данных. Рекомендации сопровождаются оценкой достоверности и физической интерпретацией, что критически важно для принятия решений технологами.

Валидация алгоритмов на производственных данных

Алгоритмы были протестированы на данных производства полимерных нанокомпозитов на основе эпоксидной матрицы с углеродными нанотрубками (УНТ) в качестве проводящего наполнителя [11].

Использовался датасет из 1 247 производственных партий, каждая из которых содержала: 87 технологических параметров и результаты измерений σ , ϵ ; 12 текстовых отчётов лаборантов; 5 изображений SEM-микроструктуры (Рисунок 2).




Рис. 1. – Форматы данных валидационного датасета

По результатам валидации алгоритмов, точность классификации «соответствует требованиям/не соответствует требованиям» составила — 94,7%; значение AUC-ROC — 0,96.

Наиболее значимыми признаками, выявленными SHAP-анализом, оказались: время ультразвуковой обработки дисперсии УНТ; скорость охлаждения после формования; однородность распределения нанонаполнителя (по SEM-анализу); влажность окружающей среды на этапе смешивания.

Система позволила снизить долю брака на 12 % за счёт раннего выявления рисков и корректировки параметров до завершения цикла производства конечного продукта (нанокompозита).

Разработанные алгоритмы реализованы в виде микросервисной архитектуры, совместимой с промышленными MES системами. Интерфейс визуализации позволяет: отслеживать текущее состояние процесса в реальном времени; просматривать историю отклонений и принятых решений, моделировать последствия изменений параметров.

Заключение

Разработанные алгоритмы интеллектуальной обработки технологической документации позволяют существенно повысить точность и оперативность контроля качества на этапах производства нанокompозитов с заданными электрофизическими характеристиками. Внедрение методов машинного обучения и семантического анализа обеспечивает автоматизированное выявление отклонений и прогнозирование свойств конечного продукта на основе исторических и текущих производственных данных. Экспериментальная валидация подтвердила эффективность предложенного подхода, демонстрируя снижение брака до 12 % и сокращение времени на принятие корректирующих решений. Полученные

результаты открывают перспективы для масштабирования системы на другие классы функциональных материалов с жёсткими требованиями к воспроизводимости свойств. Дальнейшие исследования будут направлены на интеграцию алгоритмов в цифровые двойники производственных линий для обеспечения сквозного контроля качества в режиме реального времени.

Статья подготовлена по результатам исследований, выполненных за счет бюджетных средств по государственному заданию Финуниверситета.

Литература

1. Иванников В. П., Кабакова А. В. Нанотехнологии в сфере микроэлектроники и наноэлектроники. Возможности и ограничения // Управление техносферой. – 2023. – Т. 6. – №. 1. – С. 66-92.
2. Корчагин С. А., Терин Д. В. Метод моделирования диэлектрической проницаемости анизотропного иерархически построенного нанокompозита с периодической структурой // Письма в Журнал технической физики. – 2021. – Т. 47. – №. 16. – С. 3-5.
3. Rahmati M. Electrospinning for tissue engineering applications/ Rahmati M., Mills D. K., Urbanska A. M., Saeb M. R., Venugopal J. R., Ramakrishna S., Mozafari // Progress in Materials Science. –2021. –V. 117. –P. 100721
4. Евстропьев С. К., Шелеманов А.А., Никоноров Н.В., Караваева А.В., Дукельский К.В., Полищук Г.С., Гаврилова М.А., Портнова К.А., Багров И.В. Синтез и исследование структуры и свойств фотокаталитических нанокompозитов системы Cu/ZnO-ZnCr₂O₄ // Научно-технический вестник информационных технологий, механики и оптики. – 2025. – Т. 25. – №. 2. – С. 199-211.

5. Худайбердиева Н. А., Якшимурадов Х., Байрамдурдыев А. Наноккомпозиты: революционные материалы для будущего //Вестник науки. – 2024. – Т. 4. – №. 5 (74). – С. 1675-1678.
6. Семёнов А. А., Бельтюков Я. М. Упругие свойства наноккомпозитов с аморфной матрицей //Физика твердого тела. – 2025. – Т. 67. – №. 4. – С. 747-755.
7. Lalire T., Longuet C., Taguet A. Electrical properties of graphene/multiphase polymer nanocomposites: A review // Carbon. – 2024. – Т. 225. – С. 119055.
8. Soori M., Arezoo B., Dastres R. Virtual manufacturing in industry 4.0: A review //Data Science and Management. – 2024. – Т. 7. – №. 1. – С. 47-63.
9. Кобзев В. В., Скоробогатов А. С. Разработка концептуальной модели смарт-производства для предприятий машиностроения // Техника. – 2025. – Т. 1. – С. 3.
10. Baptista M. L., Goebel K., Henriques E. M. P. Relation between prognostics predictor evaluation metrics and local interpretability SHAP values //Artificial Intelligence. – 2022. – Т. 306. – С. 103667.
11. Корчагин С. А. Математическое моделирование электропроводности наноккомпозита на основе углеродных нанотрубок с учетом эффекта волнистости и индекса дисперсии //Инженерный вестник Дона. – 2024. – №. 3. URL: ivdon.ru/magazine/archive/n3y2024/9073.

References

1. Ivannikov V. P., Kabakova A. V. Upravlenie tekhnosferoj. 2023. V. 6(1). pp. 66-92.
2. Korchagin S. A., Terin D. V. Pisma v Zhurnal tekhnicheskoy fiziki. 2021. V. 47(16). pp. 3-5.
3. Rahmati M. Progress in Materials Science. 2021. V. 117. P. 100721.



4. Evstrop'ev S. K., Shelemanov A.A., Nikonorov N.V., Karavaeva A.V., Dukel'sky K.V., Polishchuk G.S., Gavrilova M.A., Portnova K.A., Bagrov I.V. Nauchno-tekhnicheskij vestnik informacionnyh tekhnologij, mekhaniki i optiki. 2025. V. 25(2). pp. 199-211.
5. Hudajberdieva N. A., YAkshimuradov H., Bajramdurdyev. Vestnik nauki. 2024. V. 4 (5). pp. 1675-1678.
6. Semyonov A. A., Bel'tyukov Ya. M. Fizika tverdogo tela. 2025. V. 67(4). pp. 747-755.
7. Lalire T., Longuet C., Taguet A. Carbon. 2024. V. 225. P. 119055.
8. Soori M., Arezoo B., Dastres R. Data Science and Management. 2024. V. 7(1). pp. 47-63.
9. Kobzev V. V., Skorobogatov A. S. Tekhnika. 2025. V. 1. P. 3.
10. Baptista M. L., Goebel K., Henriques E. M. P. Artificial Intelligence. – 2022. V. 306. P. 103667.
11. Korchagin S. A. Inzhenernyj vestnik Dona. 2024. V. 3. URL: ivdon.ru/magazine/archive/n3y2024/9073.

Дата поступления: 13.09.2025

Дата публикации: 26.10.2025