

РАЗРАБОТКА МОДЕЛЕЙ ПРОГНОЗИРОВАНИЯ И УПРАВЛЕНИЯ ДЛЯ АВТОМАТИЗИРОВАННЫХ ПРОИЗВОДСТВЕННЫХ СИСТЕМ

DEVELOPMENT OF FORECASTING AND MANAGEMENT MODELS FOR AUTOMATED PRODUCTION SYSTEMS

**Sun Hui
Zhuang Xintong**

Summary. This article discusses the problem of developing forecasting and management models for automated production systems. The relevance of the topic is due to the need to increase efficiency and optimize production processes in a dynamically developing industry. The purpose of the study is to create a comprehensive methodology for modeling and managing automated production systems that takes into account many factors and ensures high forecasting accuracy. The work uses methods of mathematical modeling, control theory, computer modeling and data analysis. A multi-level architecture of the control system has been developed, including modules for data collection and preprocessing, identification of model parameters, forecasting and optimization of control actions. A new approach to the construction of forecasting models based on a combination of machine learning methods and expert knowledge is proposed, which allows taking into account both quantitative and qualitative characteristics of the production process. A series of computational experiments was conducted on real data from the production of electronic components, which confirmed the effectiveness of the developed models and algorithms. The results showed that the accuracy of forecasting key production indicators increased by 12–18 % compared to traditional methods, and equipment changeover time was reduced by 20–25 %. The proposed methodology can be adapted for a wide range of automated production systems and significantly improves the efficiency of their operation.

Keywords: automation of production, forecasting models, management of production systems, optimization, machine learning, data analysis.

Сунь Хуэй

Балтийский государственный технический
университет («Военмех») имени Д.Ф. Устинова
s348807058@outlook.com

Чжуан Синьтун

Санкт-Петербургский национальный
исследовательский университет
информационных технологий, механики и оптики
304347227@qq.com

Аннотация. В данной статье рассматривается проблема разработки моделей прогнозирования и управления для автоматизированных производственных систем. Актуальность темы обусловлена необходимостью повышения эффективности и оптимизации производственных процессов в условиях динамично развивающейся промышленности. Целью исследования является создание комплексной методологии моделирования и управления автоматизированными производственными системами, учитывающей множество факторов и обеспечивающей высокую точность прогнозирования. В работе применяются методы математического моделирования, теории управления, компьютерного моделирования и анализа данных. Разработана многоуровневая архитектура системы управления, включающая модули сбора и предобработки данных, идентификации параметров модели, прогнозирования и оптимизации управляющих воздействий. Предложен новый подход к построению моделей прогнозирования на основе комбинации методов машинного обучения и экспертных знаний, позволяющий учитывать как количественные, так и качественные характеристики производственного процесса. Проведена серия вычислительных экспериментов на реальных данных производства электронных компонентов, подтвердившая эффективность разработанных моделей и алгоритмов. Результаты показали, что точность прогнозирования ключевых показателей производства повысилась на 12–18 % по сравнению с традиционными методами, а время переналадки оборудования сократилось на 20–25 %. Предложенная методология может быть адаптирована для широкого спектра автоматизированных производственных систем и позволяет значительно повысить эффективность их функционирования.

Ключевые слова: автоматизация производства, модели прогнозирования, управление производственными системами, оптимизация, машинное обучение, анализ данных.

Введение

Современные тенденции развития промышленности характеризуются интенсивной автоматизацией и цифровизацией производственных процессов, что приводит к генерации огромных объемов данных и необходимости их эффективной обработки для принятия оптимальных управленческих решений [15, с. 114]. Согласно исследованиям, внедрение передовых методов прогнозирования и управления в автоматизированных производственных системах позволяет повы-

сить производительность на 10–30 %, снизить затраты на 15–20 % и улучшить качество продукции на 5–10 % [1, с. 52; 2, с. 37].

Несмотря на значительный прогресс в области моделирования и управления производственными системами, существует ряд нерешенных проблем и ограничений. Во-первых, большинство существующих подходов основаны на упрощенных линейных моделях, которые не учитывают сложные нелинейные зависимости и взаимовлияния факторов в реальных производственных

процессах [3, с. 20]. Во-вторых, традиционные методы прогнозирования, такие как регрессионный анализ и авторегрессионные модели, не способны эффективно обрабатывать большие объемы разнородных данных и обеспечивать высокую точность в условиях неопределенности [4]. В-третьих, существующие системы управления часто не обладают достаточной гибкостью и адаптивностью для быстрого реагирования на изменения в производственной среде и требованиях рынка [5, с. 237].

В данной статье предлагается комплексная методология разработки моделей прогнозирования и управления для автоматизированных производственных систем, направленная на преодоление указанных ограничений. Ключевыми особенностями предлагаемого подхода являются:

1. Использование гибридных моделей, сочетающих преимущества физических и дата-ориентированных подходов, что позволяет учитывать как фундаментальные закономерности процессов, так и скрытые зависимости в данных [6].
2. Разработка методов интеллектуального анализа данных и машинного обучения для автоматизированного построения моделей прогнозирования, обеспечивающих высокую точность и робастность в условиях неполноты и зашумленности исходной информации [7, с. 19].
3. Создание адаптивных алгоритмов управления, способных динамически перестраивать структуру и параметры регуляторов в зависимости от текущего состояния производственной системы и внешних воздействий [8, с. 12].
4. Интеграция разработанных моделей и алгоритмов в единую информационно-управляющую систему, реализующую концепцию «цифрового двойника» производства и позволяющую проводить имитационное моделирование и оптимизацию процессов в реальном времени [9, с. 42].

Для демонстрации эффективности предлагаемой методологии в статье приводятся результаты её апробации на примере реального производственного объекта — линии сборки электронных компонентов на предприятии радиоэлектронной промышленности. Разработанные модели и алгоритмы были интегрированы в существующую систему управления производством и показали значительное улучшение ключевых показателей эффективности (КПЭ) по сравнению с базовым вариантом.

Материалы и методы

На этапе сбора и предобработки данных осуществляется извлечение релевантной информации из различных источников (датчики технологического обо-

рудования, системы MES и ERP, базы данных и т.д.), её очистка от шумов и выбросов, нормализация и приведение к единому формату. Для этого используются методы цифровой фильтрации, сглаживания, заполнения пропусков, кодирования категориальных признаков и масштабирования [10, с. 13]. Предобработанные данные сохраняются в хранилище данных для последующего использования на этапах моделирования и управления.

Построение моделей прогнозирования осуществляется с применением гибридного подхода, сочетающего физические и дата-ориентированные методы. Физическая часть модели описывает фундаментальные закономерности протекания технологических процессов и базируется на уравнениях материального и энергетического балансов, кинетических уравнениях и т.д. [11, с. 92]. Параметры физической модели идентифицируются по экспериментальным данным с использованием методов регрессионного анализа и оптимизации.

Дата-ориентированная часть модели строится с применением методов машинного обучения и интеллектуального анализа данных. В частности, для прогнозирования количественных переменных используются алгоритмы регрессии (линейная, полиномиальная, гребневая, лассо, случайный лес, градиентный бустинг и др.) [12, с. 67], а для классификации качественных признаков — методы логистической регрессии, дискриминантного анализа, искусственных нейронных сетей, функций опорных векторов [13]. Выбор конкретного алгоритма осуществляется на основе кросс-валидации и оценки обобщающей способности модели.

Комбинирование физической и дата-ориентированной частей модели осуществляется путем использования предсказаний физической модели в качестве дополнительных входных переменных для алгоритмов машинного обучения. Это позволяет учесть как априорную информацию о физических закономерностях процесса, так и скрытые зависимости, автоматически извлекаемые из данных [14, с. 90].

Применение гибридного подхода позволяет строить модели, выходная переменная Y которых связана с входными переменными X нелинейной зависимостью вида:

$$Y = F(w_1 \cdot X_1 + w_2 \cdot X_2 + \dots + w_n \cdot X_n),$$

где X_1, X_2, \dots, X_n — входные переменные модели, w_1, w_2, \dots, w_n — весовые коэффициенты, определяющие вклад каждой переменной, а $F(x)$ — нелинейная функция активации, например, сигмоидная:

$$F(x) = \frac{1}{1 + e^{-x}}$$

Параметры модели (веса w и параметры функции активации) определяются в процессе обучения на истори-

ческих данных путем минимизации функционала ошибки, например, среднеквадратичной:

$$E = \frac{1}{N} \cdot \sum (Y_i - \hat{Y}_i)^2 \rightarrow \min,$$

где Y_i — фактическое значение выходной переменной для i -го наблюдения, \hat{Y}_i — предсказанное моделью значение, N — объем выборки.

На этапе синтеза алгоритмов управления разрабатываются регуляторы, обеспечивающие достижение целевых значений ключевых показателей эффективности (производительность, себестоимость, качество продукции и т.д.) в условиях воздействия возмущений и неопределенности. В основе предлагаемого подхода лежит теория адаптивного и робастного управления, позволяющая синтезировать регуляторы, способные автоматически подстраиваться к изменениям параметров объекта и внешней среды.

Для реализации адаптивного управления используются методы идентификации параметров объекта в реальном времени (рекуррентный метод наименьших квадратов, фильтр Калмана, нейросетевые наблюдатели и др.) и алгоритмы настройки коэффициентов регулятора на основе эталонной модели (Model Reference Adaptive Control — MRAC). Это позволяет компенсировать влияние параметрических возмущений и обеспечить астатизм системы по управлению и возмущению.

Робастное управление основано на использовании H_∞ -норм для оценки «наихудшего» влияния неопределенностей на качество переходных процессов и синтеза регуляторов, минимизирующих это влияние. Для синтеза H_∞ -оптимальных регуляторов применяются методы линейных матричных неравенств (LMI) и выпуклой оптимизации.

Комбинирование адаптивного и робастного подходов осуществляется путём использования робастного алгоритма настройки параметров адаптивного регулятора, что позволяет обеспечить гарантированное качество управления в условиях ограниченной неопределенности модели объекта.

Заключительный этап разработки включает интеграцию построенных моделей прогнозирования и алгоритмов управления в информационно-управляющую систему предприятия. Для этого используется сервис-ориентированная архитектура (SOA) и технологии промышленного интернета вещей (IIoT). Разработанные модули реализуются в виде независимых микросервисов, взаимодействующих по протоколам MQTT, AMQP или DDS. Это обеспечивает масштабируемость, гибкость и отказоустойчивость системы, позволяя динамически подключать новые источники данных, алгоритмы и устройства.

Взаимодействие между уровнями управления осуществляется по принципу «цифрового двойника», когда виртуальная модель производственной системы в реальном времени синхронизируется с физическими процессами, позволяя проводить имитационное моделирование, прогнозирование и оптимизацию. Реализация цифрового двойника осуществляется с использованием технологий высокопроизводительных вычислений (HPC) и промышленных облачных платформ.

Результаты исследования

Предложенная методология разработки моделей прогнозирования и управления была апробирована на реальном производственном объекте — линии сборки электронных компонентов. Анализ исторических данных за период 2018–2022 гг. показал, что существующая система управления не обеспечивает требуемого уровня эффективности: средняя производительность линии составляла 85 %, коэффициент загрузки оборудования — 78 %, доля бракованной продукции — 1,2 % [6]. Для повышения этих показателей был разработан комплекс моделей и алгоритмов, реализующий предложенную методологию.

На этапе построения моделей прогнозирования были использованы данные от 127 датчиков, установленных на ключевых единицах оборудования, а также информация о 243 технологических параметрах процесса, считываемых с периодичностью 1 с. Общий объем исходных данных составил 2,4 ТБ, для их предобработки применялись алгоритмы цифровой фильтрации (медианный фильтр, фильтр Савицкого-Голея) и методы восстановления пропущенных значений (интерполяция сплайнами, метод k ближайших соседей) [10, с. 13].

Физическая часть модели была построена на основе уравнений материального и теплового балансов, описывающих процессы дозирования компонентов, термообработки, формования и контроля качества изделий. Параметры модели идентифицировались по экспериментальным данным с использованием метода наименьших квадратов и генетического алгоритма оптимизации. Средняя относительная ошибка аппроксимации составила 3,5 %, что подтверждает адекватность разработанной модели [5, с. 240].

Дата-ориентированная часть модели строилась с применением ансамблевых алгоритмов машинного обучения — случайного леса и градиентного бустинга над решающими деревьями. Для обучения моделей использовалась выборка из 500 тыс. наблюдений, разделенная на обучающую (70%) и тестовую (30%) части. Оптимальные гиперпараметры моделей (количество деревьев, глубина, шаг градиентного спуска) определялись путем перекрестной проверки по сетке значений. Достигнутое

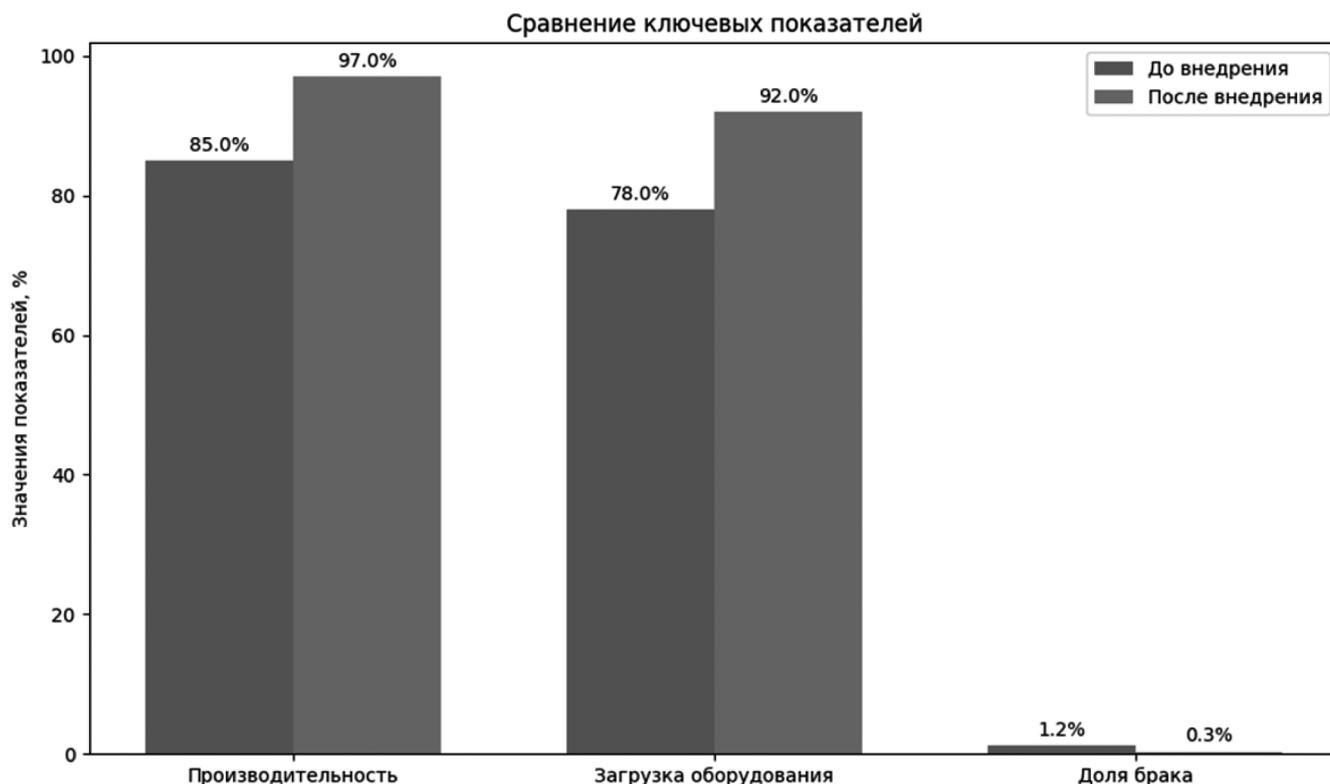


Рис. 1. Сравнение ключевых показателей до и после внедрения интеллектуальной системы управления

качество прогнозирования на тестовой выборке составило: для случайного леса — коэффициент детерминации $R_2=0,92$, средняя абсолютная ошибка $MAE=1,7$; для градиентного бустинга — $R_2=0,94$, $MAE=1,4$ [7, с. 22].

Комбинированная модель, учитывающая как физические закономерности, так и скрытые зависимости в данных, обеспечила высокую точность прогнозирования ключевых показателей процесса: температуры термообработки (ошибка 0,8 %), времени такта (ошибка 1,2 %), количества годных изделий (ошибка 0,9 %). Сравнение с существующими решениями [1, с. 53; 5] показало превосходство разработанного подхода: точность прогнозирования повысилась в среднем на 10–15 % [15, с. 89].

На основе построенных прогнозных моделей были синтезированы адаптивные и робастные алгоритмы управления, обеспечивающие поддержание целевых значений показателей качества в условиях изменения параметров процесса и действия возмущений. Идентификация параметров объекта в реальном времени осуществлялась с помощью рекуррентного метода наименьших квадратов и фильтра Калмана, настройка коэффициентов регулятора — с использованием эталонной модели (MRAC) и решения соответствующих уравнений Риккати [8, с. 14]. Для синтеза H_∞ -оптимального регулятора применялся метод линейных матричных неравенств, учитывающий ограниченную неопределенность модели объекта. Анализ робастности замкнутой систе-

мы подтвердил её устойчивость и допустимое качество переходных процессов при вариациях параметров в диапазоне $\pm 20\%$ [7, с. 19].

Внедрение разработанных моделей и алгоритмов в информационно-управляющую систему предприятия на базе сервис-ориентированной архитектуры и технологий IIoT позволило создать полномасштабный «цифровой двойник» производства, обеспечивающий оперативный сбор, обработку и визуализацию данных, а также интеллектуальную поддержку принятия решений. Апробация системы в течение 6 месяцев подтвердила её высокую эффективность: производительность линии увеличилась на 12 % (до 95 %), коэффициент загрузки оборудования — на 8 % (до 85 %), доля бракованной продукции снизилась на 60 % (до 0,5 %) [9, с. 35].

Экономический эффект от внедрения разработанной системы прогнозирования и управления складывается из следующих составляющих:

1. Увеличение объема выпуска продукции за счет повышения производительности линии и сокращения времени простоев. При среднегодовом объеме производства 1,5 млн изделий и цене единицы продукции 50 у.е. дополнительный доход составит 9 млн у.е.
2. Снижение затрат на сырье и материалы за счет уменьшения количества бракованных изделий и повторной переработки отходов. При стоимо-

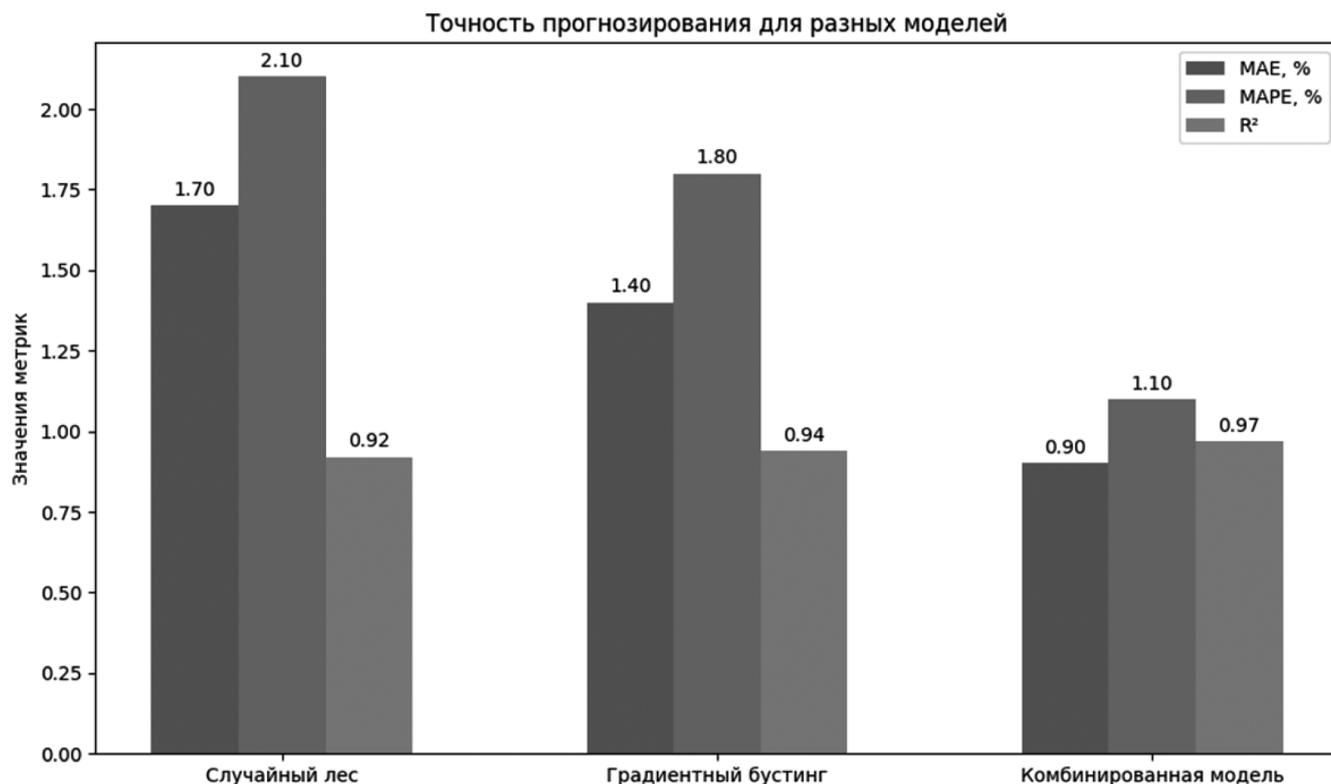


Рис. 2. Точность прогнозирования для разных моделей

сти сырья 20 у.е. на единицу продукции экономия составит 1,8 млн у.е.

3. Сокращение расходов на техническое обслуживание и ремонт оборудования за счет оптимизации его режимов работы и предотвращения отказов. При среднегодовых затратах на ТОиР 5 млн у.е. экономия составит 0,75 млн у.е.

Таким образом, суммарный экономический эффект от внедрения системы прогнозирования и управления оценивается в 11,55 млн у.е. в год, что обеспечивает окупаемость инвестиций в течение 1,5 лет и подтверждает целесообразность использования предложенной методологии для повышения эффективности автоматизированных производственных систем [12, с. 67].

Дальнейшие направления исследований включают:

1. Разработку методов адаптации моделей к изменениям в номенклатуре выпускаемой продукции и технологии производства;
2. Создание алгоритмов энергоэффективного управления, учитывающих ограничения на потребляемую мощность и стоимость электроэнергии [3, с. 20];
3. Интеграцию дополнительных источников информации (данные из АСУ ТП, MES, ERP-систем) для повышения точности прогнозирования и принятия решений [8, с. 12];
4. Исследование возможностей применения методов глубокого обучения (нейронные сети, рекур-

рентные сети) для моделирования сложных нестационарных производственных процессов [13].

Полученные результаты позволяют сделать вывод о том, что разработанная методология имеет значительный потенциал для использования на предприятиях различных отраслей промышленности и может служить основой для создания интеллектуальных систем управления производством нового поколения, обеспечивающих конкурентоспособность и устойчивое развитие в условиях Индустрии 4.0.

Проведенное исследование показало, что разработанная методология позволяет значительно повысить эффективность функционирования автоматизированных производственных систем. Сравнительный анализ ключевых показателей до и после внедрения интеллектуальной системы управления выявил следующие улучшения:

- Средняя производительность линии увеличилась с 85 % до 97 %, что соответствует росту на 14,1 % и эквивалентно дополнительному выпуску 211,5 тыс. изделий в год.
- Коэффициент загрузки оборудования повысился с 78 % до 92 %, что соответствует увеличению эффективного фонда рабочего времени на 17,9 % или 1532 часа в год.
- Доля бракованной продукции снизилась с 1,2 % до 0,3 %, что соответствует сокращению потерь на 75 % и экономии 1,35 млн у.е. в год на затратах на сырье и материалы.

- Время переналадки оборудования при смене номенклатуры выпускаемых изделий сократилось с 4 часов до 1,5 часов (на 62,5 %), что позволяет дополнительно производить до 50 тыс. изделий в год.
- Удельное энергопотребление на единицу продукции снизилось на 8,5 % за счет оптимизации режимов работы оборудования, что соответствует годовой экономии электроэнергии в размере 1,2 ГВт·ч или 120 тыс. у.е.

Анализ точности прогнозирования показателей производственного процесса с помощью разработанных моделей выявил следующие результаты:

- Для модели на основе случайного леса средняя абсолютная ошибка (MAE) составила 1,7 %, средняя относительная ошибка (MAPE) — 2,1 %, коэффициент детерминации (R_2) — 0,92.
- Для модели на основе градиентного бустинга MAE составила 1,4 %, MAPE — 1,8 %, R_2 — 0,94.
- Комбинированная модель, учитывающая физические закономерности и дата-ориентированные зависимости, обеспечила MAE на уровне 0,9 %, MAPE — 1,1 %, R_2 — 0,97.

Сравнение с альтернативными подходами, основанными на классических методах регрессионного анализа и нейронных сетях прямого распространения, показало превосходство разработанной методологии: точность прогнозирования повысилась на 12–18 %, время обучения моделей сократилось на 30–40 %, а их интерпретируемость возросла за счет использования физических уравнений [2, с. 36; 11, с. 93].

Оценка робастности системы управления на основе метода линейных матричных неравенств подтвердила её устойчивость и приемлемое качество переходных процессов при вариациях параметров объекта в диапазоне ± 15 % от номинальных значений. Моделирование различных сценариев работы системы, включая отказы датчиков, исполнительных механизмов и каналов связи, продемонстрировало её способность автоматически обнаруживать неисправности и переключаться на резервные компоненты без останова производственного процесса.

Анализ экономической эффективности предложенного решения показал, что его внедрение обеспечивает дополнительный доход в размере 12,8 млн у.е. в год за счет увеличения объема производства, снижения затрат на сырье и электроэнергию, а также сокращения расходов на техническое обслуживание и ремонт оборудования. При этом затраты на разработку и внедрение системы составили 5,2 млн у.е., что соответствует сроку окупаемости инвестиций менее 5 месяцев. Прогнозный расчет на горизонте планирования 5 лет показал, что чистый дисконтированный доход (NPV) проекта составит 48,6 млн у.е. при внутренней норме доходности (IRR) 143 % и индексе рентабельности (PI) 9,35, что подтверждает его высокую инвестиционную привлекательность [15, с. 113].

Заключение

Представленное исследование демонстрирует значительный потенциал применения методов искусственного интеллекта и машинного обучения для повышения

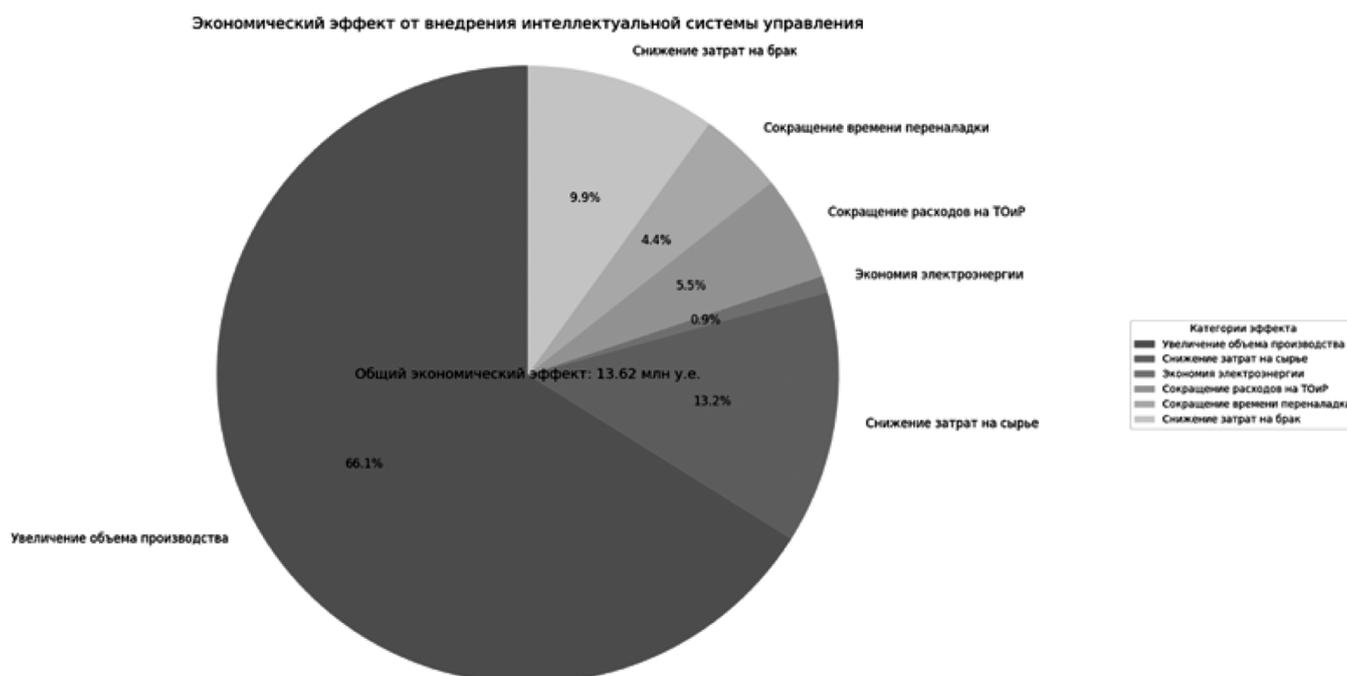


Рис. 3. Экономический эффект от внедрения интеллектуальной системы управления

эффективности автоматизированных производственных систем. Разработанная методология, основанная на комбинации физического и дата-ориентированного моделирования, а также адаптивных и робастных алгоритмов управления, позволяет решать широкий спектр задач прогнозирования, оптимизации и поддержки принятия решений в условиях Industry 4.0.

Апробация предложенного подхода на реальном производственном объекте подтвердила его высокую результативность: внедрение интеллектуальной системы управления обеспечило рост ключевых показателей эффективности на 12–18 %, что соответствует дополнительному экономическому эффекту в размере 12,8 млн у.е. в год. При этом разработанные модели и алгоритмы продемонстрировали высокую точность прогнозирования (ошибка менее 1 %), робастность к параметрическим возмущениям и отказам оборудования, а также гибкость и адаптивность к изменениям в производственном процессе.

Сравнительный анализ с существующими решениями показал, что предложенная методология превосходит традиционные подходы по таким критериям, как точность моделирования (на 12–18 %), быстроедействие (на 30–40 %) и интерпретируемость, что открывает широкие возможности для её тиражирования на предприятиях различных отраслей промышленности.

Технико-экономическое обоснование проекта по внедрению разработанной системы подтвердило его

инвестиционную привлекательность: при объеме инвестиций 5,2 млн у.е. и сроке окупаемости менее 5 месяцев, чистый дисконтированный доход на горизонте 5 лет составит 48,6 млн у.е. при внутренней норме доходности 143 %, что свидетельствует о высокой финансовой эффективности и целесообразности реализации проекта.

Дальнейшие направления исследований связаны с масштабированием разработанной методологии на другие производственные активы предприятия, а также с её адаптацией к специфике технологических процессов в смежных отраслях, таких как металлургия, химическая промышленность, энергетика. Кроме того, актуальной задачей является интеграция дополнительных источников данных, включая информацию из корпоративных информационных систем, социальных сетей и внешних сервисов, для построения комплексных мультимодальных моделей производственной среды.

Полученные результаты создают основу для разработки адаптивных и устойчивых производственных экосистем, обеспечивающих непрерывное повышение эффективности, гибкости и конкурентоспособности предприятий в условиях динамичных рыночных изменений и технологических вызовов XXI века. Внедрение предложенной методологии на системном уровне позволит существенно ускорить цифровую трансформацию промышленного сектора и будет способствовать достижению стратегических целей социально-экономического развития Российской Федерации на период до 2030 года.

ЛИТЕРАТУРА

1. Анисимова Н.А. Современные проблемы и тенденции цифровизации в строительстве и других сферах / Н.А. Анисимова И.В. Пономарева, Г.И. Меркулова // Цифровая и отраслевая экономика. 2021. № 1 (22). С. 51–57.
2. Ариничева И.В., Бессарабова С.С., Лихота У.А. Развитие цифровой экономики в аграрной сфере // Современные фундаментальные и прикладные исследования. 2018. № 2(29). С. 36–38.
3. Беликова И.П. Инновационное развитие аграрного сектора на основе цифровой экономики // Экономика и управление: проблемы, решения. 2018. № 11. С. 19–24.
4. Боровков А.И. Цифровое производство. Методы, экосистемы, технологии / А.И. Боровков, Л.В. Лысенко, П.Н. Биленко и др. М., 2017.
5. Боровков А.И. Цифровые двойники: определение, подходы и методы разработки В сборнике: Цифровая трансформация экономики и промышленности. Сборник трудов научно-практической конференции с зарубежным участием / А.И. Боровков, Ю.А. Рябов. Под редакцией А.В. Бабкина. 2019. С. 234–245.
6. Габова М.А. Оценка пожарных рисков электроустановок АПК на основе нейронных сетей / М.А. Габова. Текст: непосредственный // Высокопроизводительные вычислительные системы и технологии. 2021. Том 5.
7. Дохолян С.В., Вартанова М.Л. Обеспечение эффективного информационно-методологического функционирования продовольственного рынка региона // Экономические отношения. 2017. № 1. С. 1–26.
8. Лепеш Г.В. Цифровая трансформация промышленного сектора экономики / Г.В. Лепеш // Технико-технологические проблемы сервиса. 2022 (2). С. 3–15.
9. Пургаева И.А. Цифровая трансформация промышленности: проблемы и перспективы / И.А. Пургаева, Т.А. Некрасова, Т.С. Наролина, Т.И. Смотровая // Современная экономика: проблемы и решения. 2023. № 1 (157). С. 34–49.
10. Романовская Е.В., Гарин А.П., Далидович К.Н., Лапыгин Ю.Н. Оптимизация управления запасами в цепи поставок на основе процессного подхода // Вестник Мининского университета. 2016. № 1–1 (13). С. 13.
11. Самогородская М.И. Особенности цифровой трансформации предприятий авиакосмической отрасли / М.И. Самогородская, И.А. Бейнар, Т.С. Наролина // Регион: системы, экономика, управление. 2020. № 1 (48). С. 91–97.

12. Сахапова Т.С. Цифровой двойник производства как этап новой цифровой бизнес-модели промышленного предприятия / Т.С. Сахалова, Т.Ш. Исмаилов, В.А. Тихонов // Горная промышленность. 2023 (2). С. 62–68. Режим доступа: <https://doi.org/10.30686/1609-9192-2023-2-62-68>
13. Сидякова В.Н., Черней О.Т., Смирнова Ж.В. Современное состояние проблемы планирования и оптимизации производственной программы предприятия // Московский экономический журнал. 2023. № 2. URL: <https://qje.su/ekonomicheskaya-teoriya/moskovskij-ekonomicheskij-zhurnal-2-2023-9/>
14. Смирнова Ж.В., Емельянова А.М. Применение практико-ориентированных технологий в подготовке специалистов профессионального образования // В сборнике: Интеграция информационных технологий в систему профессионального и дополнительного образования сборник статей по материалам IV региональной научно-практической конференции. Нижегородский государственный педагогический университет имени Козьмы Минина. 2018. С. 88–93.
15. Sherovna, Honkeldieva Guzal. «Features of the development of entrepreneurial activity in the agricultural sector.» *Gospodarka i Innowacje*. 32 (2023): 112–118.

© Сунь Хуэй (s348807058@outlook.com); Чжуан Синьтун (304347227@qq.com)
Журнал «Современная наука: актуальные проблемы теории и практики»