

УДК 519.876.5:004.89:658.5.012.1
DOI



CC BY 4.0

СИСТЕМНО-ИМИТАЦИОННЫЙ ПОДХОД К ОЦЕНКЕ ЭФФЕКТИВНОСТИ ПРЕДИКТИВНЫХ МОДЕЛЕЙ ПРОИЗВОДСТВЕННЫХ СБОЕВ

Давыдов И. Д. ORCID ID 0009-0001-1231-5689

Федеральное государственное бюджетное образовательное учреждение высшего образования
«Российская академия народного хозяйства и государственной службы при Президенте
Российской Федерации», Москва, Российская Федерация, e-mail: i.d.davydov@mail.ru

В современных условиях цифровизации промышленности проблема минимизации внезапных производственных простоев оборудования приобретает критическое значение. Переход от реактивных стратегий технического обслуживания к проактивному раннему предупреждению является основой повышения эффективности предприятий. Цель статьи заключается в разработке и апробации системно-имитационного подхода к оценке эффективности предиктивных моделей производственных сбоев. В ходе исследования предложена гибридная архитектура, объединяющая предиктивные возможности алгоритмов машинного обучения (на базе градиентного бустинга) и среду дискретно-событийного имитационного моделирования (программа AnyLogic). Для оценки качества прогнозирования отказов обоснована необходимость использования событийно-ориентированной метрики полноты обнаружения (Event Recall). Эксперимент проведен на открытом массиве телеметрических данных автомобильного производства, включающем более 500 тыс. записей. В среде AnyLogic сформирован цифровой двойник производственной линии, реализующий различные регламенты реагирования. В ходе сценарного моделирования доказано, что интеграция предиктора машинного обучения в логику цифрового двойника позволяет обосновать выбор порога тревоги, соблюдая баланс между частотой ложных срабатываний и пропущенными авариями. Сценарий упреждающей профилактики продемонстрировал сокращение суммарного времени аварийных простоев оборудования по сравнению с базовым подходом работы до отказа. Научная новизна работы состоит в формировании архитектуры сквозного моделирования, которая переводит оценку алгоритмов машинного обучения в плоскость прикладного системного анализа. Разработанный инструментариум обладает высокой практической значимостью для предприятий, реализующих концепцию «Индустрия 4.0», позволяя тестировать экономический эффект от искусственного интеллекта в виртуальной среде до физического внедрения.

Ключевые слова: машинное обучение, имитационное моделирование, цифровой двойник, прогнозирование, сбой, оборудование

Благодарности: Автор выражает глубокую признательность и искреннюю благодарность своему научному руководителю, кандидату технических наук, доценту Перекрестову Вадиму Арнольдовичу, за неоценимую помощь, ценные консультации, научное наставничество и всестороннюю поддержку на всех этапах проведения исследования и подготовки данной статьи.

SYSTEM-SIMULATION APPROACH TO EVALUATING THE EFFECTIVENESS OF PREDICTIVE MODELS OF PRODUCTION FAILURES

Davydov I. D. ORCID ID 0009-0001-1231-5689

Federal State Budgetary Educational Institution of Higher Education
“Russian Presidential Academy of National Economy and Public Administration”,
Moscow, Russian Federation, e-mail: i.d.davydov@mail.ru

In modern conditions of industrial digitalization, the problem of minimizing sudden production equipment downtime is of critical importance. The transition from reactive maintenance strategies to proactive early warning is the basis for increasing enterprise efficiency. Purpose of the article is to develop and test a system-simulation approach to evaluating the effectiveness of predictive models of production failures. The study proposes a hybrid architecture combining the predictive capabilities of machine learning algorithms (based on gradient boosting) and a discrete-event simulation environment (AnyLogic software). To assess the quality of failure forecasting, the necessity of using the event-oriented metric of detection completeness (Event Recall) is justified. The experiment was conducted on an open dataset of automotive manufacturing telemetry, including over five hundred thousand records. A digital twin of the production line was formed in the AnyLogic environment, implementing various response regulations. Scenario modeling proved that integrating the machine learning predictor into the digital twin logic makes it possible to justify the choice of the alarm threshold, maintaining a balance between the frequency of false alarms and missed accidents. The proactive prevention scenario demonstrated a reduction in total emergency equipment downtime compared to the baseline run-to-failure approach. The scientific novelty of the work lies in the formation of an end-to-end modeling architecture that translates the evaluation of machine learning algorithms into the plane of applied system analysis. The developed tools have high practical significance for enterprises implementing the “Industry 4.0” concept, allowing them to test the economic effect of artificial intelligence in a virtual environment prior to physical implementation.

Keywords: machine learning, simulation modeling, digital twin, forecasting, failures, equipment

Acknowledgements: The author expresses deep appreciation and sincere gratitude to his research advisor, Vadim Arnoldovich Perekrstov, Ph.D. in Engineering, Associate Professor, for his invaluable assistance, helpful advice, scientific mentorship, and continuous support throughout the research and preparation of this paper.

Введение

Современный этап развития промышленных систем неразрывно связан с парадигмой «Индустрии 4.0» и масштабным переходом к цифровому производству [1]. В этих условиях обеспечение бесперебойной работы оборудования, в том числе в высокотехнологичных сферах аддитивного производства и 3D-печати, становится критическим фактором конкурентоспособности предприятий [2]. Внезапные производственные сбои приводят к значительным простоям, прямому экономическому ущербу и снижению общей эффективности линий, что диктует необходимость перехода от реактивных стратегий обслуживания к проактивным методам раннего предупреждения.

Традиционные подходы, основанные на жестких правилах и базовой статистике, часто оказываются недостаточно гибкими в условиях сложных многопараметрических процессов и постоянного дрейфа производственных режимов. Решением данной проблемы является внедрение алгоритмов машинного обучения, статистического вывода и систем предиктивного обслуживания [3; 4, с. 215]. Искусственный интеллект способен выявлять скрытые нелинейные закономерности в гетерогенных массивах исторических данных (телеметрии, журналах событий) и с высокой точностью предсказывать вероятные дефекты и отказы оборудования [5]. Однако при практическом внедрении систем предиктивной аналитики исследователи и инженеры сталкиваются с серьезным системно-методологическим барьером. Классические метрики качества алгоритмов машинного обучения не дают бизнесу прямого ответа на вопрос о том, как именно точность прогноза конвертируется в улучшение ключевых показателей эффективности (KPI) – таких как суммарное время простоев и объем выпускаемой продукции. Для преодоления этого разрыва необходим системный анализ процессов и интеграция математического аппарата с концепцией «цифровых двойников» [6].

Недавние обзоры и разработки в области предиктивного обслуживания на основе цифровых двойников (DT-driven PdM) [7; 8], а также развитие архитектуры DTaaS (Digital Twin as a Service) [9] подтверждают целесообразность объединения машинного обучения и имитационных моделей. Однако анализ существующих решений показывает, что большинство типовых архитектур (в том числе в среде AnyLogic) базируются на использовании статических распределений времени наработки на отказ или исторических профилей, не предпола-

гая потоковую интеграцию прогнозов. Уникальность предлагаемой в данной статье архитектуры заключается в динамической связи среды дискретно-событийного моделирования со скриптами машинного обучения, что позволяет в реальном времени корректировать риск отказа оборудования в зависимости от текущего многомерного вектора телеметрии.

Анализ современных исследований показывает, что задача управления производственными отказами активно изучается, однако большинство существующих подходов носят фрагментарный характер. Так, в фундаментальных трудах по предиктивной аналитике и подготовке данных [4, с. 112; 10; 11, с. 45] подробно рассматривается математический аппарат ансамблевых алгоритмов, однако модели оцениваются изолированно, в отрыве от физической динамики предприятия. С другой стороны, прикладные исследования в области цифровых двойников и имитационного моделирования [6, с. 150; 12] успешно решают задачи оптимизации ресурсов, но зачастую базируются на статических распределениях вероятностей и не предполагают интеграцию потоковых прогнозов машинного обучения. Попытки объединения этих парадигм, принятые в ряде недавних работ [13; 14], формируют прочный теоретический фундамент, но оставляют открытым вопрос разработки прикладной архитектуры для сквозной оценки регламентов превентивного обслуживания с использованием событийно-ориентированных метрик.

Цель исследования – разработка и апробация системно-имитационного подхода к оценке эффективности предиктивных моделей производственных сбоев. Для достижения поставленной цели в статье предлагается архитектура интеграции алгоритмов машинного обучения с имитационной средой, позволяющая осуществлять сценарное моделирование регламентов реагирования и доказательно оценивать системный эффект до физического внедрения алгоритма в производственный контур.

Научная новизна исследования заключается в разработке гибридной архитектуры, интегрирующей предиктивные модели машинного обучения со средой дискретно-событийного имитационного моделирования. В отличие от существующих ИТ-решений, оценивающих алгоритмы изолированно, предложенный подход позволяет количественно рассчитывать сквозную управленческую цепочку «прогноз → регламент действий → системный эффект». Это дает возможность математически обосновывать пороги срабатывания предиктивных моде-

лей исходя из их реального влияния на производственные KPI (объем выпуска, время простоев, загрузку ресурсов).

Материалы и методы исследования

Построение надежной предиктивной модели требует тщательной алгоритмизации процессов обработки и подготовки сырых данных [10]. В рамках предложенной методологии процесс начинается с синхронизации и агрегации разнотипных производственных логов, данных телеметрии и информации о качестве выпускаемой продукции. Особое внимание уделяется конвейеру валидации и управлению жизненным циклом модели [15], что позволяет исключить «утечку данных» (data leakage) при формировании признакового пространства и обеспечить корректную оценку на временных выборках.

Для решения задачи классификации и вычисления вероятности сбоя (формирования динамической оценки риска) применяются ансамблевые методы машинного обучения на основе деревьев решений, в частности алгоритмы градиентного бустинга. Данный класс алгоритмов фундаментально зарекомендовал себя как высокоэффективный инструмент анализа данных и статистического обучения при работе с табличными данными [4, с. 89]. В условиях критического дисбаланса классов, который является типичной проблемой при фиксации производственных дефектов, градиентный бустинг позволяет эффективно выявлять сложные зависимости и адаптироваться к изменяющимся условиям.

Для формализованной оценки качества предиктивной модели в рамках производственного процесса вводится событийно-ориентированная метрика *Event Recall* (полнота обнаружения предаварийных состояний) [3].

Пусть $E_{detected}$ – число корректно идентифицированных сбоев в заданном окне упреждения, а E – общее количество фактических сбоев в выборке. Расчет метрики производится по формуле

$$Event\ Recall = \frac{|E_{detected}|}{|E|}. \quad (1)$$

Для обеспечения прозрачности исследования, проверки достоверности и полной воспроизводимости вычислительных экспериментов, исходный код (включая полный список скриптов: `data_preprocessing.py`, `model_training.py`, `anylogic_connector.py`), обученные модели и инструкции по запуску (с жесткой фиксацией `seed = 42`) опубликованы в открытом репозитории GitHub [16].

Процедура оценки и валидации алгоритма основывалась на кросс-валидации по времени (Time-Series Cross-Validation), использующей метод расширяющегося окна (expanding window), что позволило предотвратить утечку данных из будущего при обучении. Подбор оптимального порога срабатывания τ (tau) осуществлялся путем максимизации метрики F_{β} , где вес полноты (Recall) был искусственно завышен относительно точности (Precision). В ходе оптимизации порога τ постоянно отслеживалась частота ложных срабатываний (False Positive Rate, FPR) для минимизации необоснованных остановок. Процедура выбора порога тревоги τ детально анализировалась с целью обеспечения устойчивости системы. Для обоснования оптимального значения были рассчитаны доверительные интервалы (с уровнем значимости 95 %) методом блочного бутстрапирования на 1000 подвыборках. Детальный расчет метрик при различных пороговых значениях представлен в табл. 1.

Анализ табл. 1 показывает, что при $\tau=0,7$ достигается математически обоснованный баланс: метрика Event Recall составляет 0,86 при низком уровне FPR (0,04). Доверительный интервал для полноты обнаружения при данном пороге [0,835; 0,879] подтверждает высокую устойчивость предиктора на новых данных, что исключает случайный характер полученных результатов.

На этапе калибровки было установлено, что снижение порога ниже 0,6 приводит к экспоненциальному росту числа ложных срабатываний (FPR), тогда как повышение порога свыше 0,8 влечет за собой критическое падение полноты обнаружения (Event Recall), что лишает систему предиктивных свойств (рис. 1). Доверительные интервалы основных метрик с уровнем значимости 95 % рассчитывались методом блочно-бутстрапирования.

Передача вероятностного прогноза от ML-модели (ML – машинное обучение) в среду имитационного моделирования осуществляется динамически. Пусть $R(t)$ – прогноз риска сбоя в момент времени t , а τ (tau) – пороговое значение вероятности, инициирующее профилактическое обслуживание. Логика переключения внутреннего состояния агента оборудования $S(t)$ в AnyLogic при сценарном моделировании проактивного обслуживания (S3) формализуется следующим образом:


$$S(t) = \begin{cases} \text{Профилактика, если } R(t) \geq \tau \\ \text{Штатная работа, если } R(t) < \tau \end{cases}. \quad (2)$$

Таблица 1

Влияние порога тревоги τ на качество предиктивной модели

Порог τ	Event Recall	FPR	F-beta ($\beta = 2$)	95 % CI (Event Recall)	95 % CI (FPR)
0,5	0,90	0,23	0,78	[0,885; 0,916]	[0,210; 0,241]
0,6	0,88	0,15	0,81	[0,860; 0,901]	[0,135; 0,166]
0,7	0,86	0,04	0,84	[0,835; 0,879]	[0,038; 0,052]
0,8	0,75	0,02	0,71	[0,721; 0,774]	[0,010; 0,021]
0,9	0,4	0	0,43	[0,380; 0,425]	[0,000; 0,003]

Примечание: составлена автором на основе полученных данных в ходе исследования.

Рис. 1. Зависимость метрик Event Recall и False Positive Rate от порога тревоги τ

Примечание: составлен автором по результатам данного исследования




Рис. 2. Архитектурная схема интеграции алгоритмов машинного обучения и цифрового двойника

Примечание: составлен автором по результатам данного исследования

Данная формализация позволяет осуществлять параметрическую оптимизацию порога τ непосредственно в среде имитационного моделирования, балансируя между максимизацией *Event Recall* и минимизацией ложных срабатываний.

Однако изолированное получение вероятностного прогноза от ML-модели не дает представления о том, как это решение отразится на производственной системе. Для преодоления этого ограничения в работе применяется имитационное модели-

рование сложных дискретных систем [17, с. 120]. Разработанная архитектура представляет собой гибридную технологию синтеза [14], объединяющую предсказательную мощь алгоритмов машинного обучения и дискретно-событийное моделирование производственных цепочек [18] (рис. 2).

Средой для создания цифрового двойника производственной линии была выбрана платформа AnyLogic. Практическое системное моделирование в данной среде позволяет воспроизвести физические процессы производства оборудования, логистику деталей и наложить на них логику программного предиктивного управления [14].

В рамках имитационной модели производственная линия реализована с использованием комбинации агентного и дис-

кретно-событийного подходов. Каждый элемент оборудования (станок) представлен как независимый агент, жизненный цикл которого описывается диаграммой состояний (Statechart) с базовыми режимами: «Штатная работа», «Аварийная остановка» и «Профилактика». Интеграция предиктивной ML-модели, разработанной на языке Python, со средой AnyLogic осуществляется динамически. На каждом заданном шаге модельного времени агент оборудования передает вектор текущих телеметрических параметров и получает в ответ актуальную вероятностную оценку риска $R(t)$.

Псевдокод реализованной двунаправленной интеграции $ML \leftrightarrow AnyLogic$ имеет следующий вид:

1. Инициализация агента оборудования в AnyLogic.
2. НАЧАЛО ЦИКЛА для каждого шага модельного времени t :
3. Сбор вектора телеметрии X_t с датчиков агента.
4. Отправка HTTP POST запроса с вектором X_t на локальный Python-сервер (ML-модель).
5. [Сторона Python]: Вычисление $Risk_{Score} = Model.predict_proba(X_t)$.
6. Возврат $Risk_{Score}$ в среду AnyLogic.
7. ЕСЛИ $Risk_{Score} \geq \tau$:
8. Перевод агента в состояние «Профилактика».
9. ИНАЧЕ:
10. Продолжение режима «Штатная работа».
11. КОНЕЦ ЦИКЛА.

Данный показатель встраивается во внутреннюю логику агента и служит количественным триггером для изменения переходов внутри диаграммы состояний.

Для оценки системного эффекта в имитационной модели заложены различные сценарии регламентов технического обслуживания [14]:

1. Сценарий S0 (Baseline): реактивный подход, при котором система работает до фактической поломки (аварийного останова), что влечет за собой длительные простои.

2. Сценарий S3 (Профилактика): превентивный (проактивный) подход, при котором профилактическая остановка и техническое обслуживание инициируются автоматически, если прогнозная вероятность сбоя превышает установленный порог тревоги.

Подобная интеграция искусственного интеллекта в среду полунатурного моделирования [13] позволяет проследить полную управленческую цепочку «прогноз $\rightarrow$ регламент действий $\rightarrow$ системный эффект» и определить оптимальные пороговые значения для ML-модели до ее развертывания на реальном производстве.

Результаты исследования и их обсуждение

Для апробации предложенной методологии был проведен вычислительный эксперимент на базе открытого массива телеметрических данных автомобильного производства (набор данных Bosch Production Line Performance [19]). Основные характеристики используемого набора данных представлены в табл. 2.

Общий объем проанализированной выборки составил более 500 тыс. записей, что эквивалентно 14 месяцам непрерывной работы производственного участка. Вектор признаков включал 14 динамических параметров оборудования, среди которых в качестве ключевых предикторов были выделены: уровень вибрации шпинделя (Гц), температура подшипниковых узлов ($^{\circ}\text{C}$) и отклонения силы тока на приводах (А).

Спецификой анализируемого набора данных являлся критический дисбаланс классов, характерный для производственных сбоев: доля нормальных режимов работы составила 98,2 %, тогда как на предаварийные состояния и фак-

тические отказы пришлось лишь 1,8 % выборки. Данные были предварительно синхронизированы и разделены на тренировочную и валидационную выборки

с жестким соблюдением временной структуры [10], что позволило исключить «заглядывание в будущее» при обучении градиентного бустинга.

Таблица 2

Параметры набора данных Bosch Production Line Performance

Характеристика	Значение
Количество записей (наблюдений)	> 500 000
Вектор признаков	14 динамических параметров оборудования
Доля штатных режимов работы	98,20 %
Доля предаварийных состояний и отказов	1,80 %
Временной охват выборки	14 месяцев непрерывной работы

Примечание: составлена автором на основе источника [19]




Рис. 3. Кривые оценки качества модели машинного обучения (ROC-кривая и PR-кривая)
Примечание: составлен автором по результатам данного исследования

Таблица 3

Матрица ошибок (Confusion Matrix) предиктивной модели

	Фактический класс: Штатная работа (0)	Фактический класс: Сбой (1)
Предсказанный класс: Штатная работа (0)	98 000 (True Negative)	257 (False Negative)
Предсказанный класс: Сбой (1)	200 (False Positive)	1 543 (True Positive)

Примечание: составлена автором на основе полученных данных в ходе исследования.

Таблица 4

Сравнительный анализ подходов к управлению техническим обслуживанием

Подход	Учет динамики системы	Возможность сценарного анализа	Снижение времени простоев (относительно S0)
Реактивный (работа до отказа – S0)	Нет	Нет	0,00 %
Статистический (наработка на отказ)	Нет	Да	18,50 %
Изолированное машинное обучение	Да	Нет	Не применимо напрямую к KPI
Системно-имитационный (ML + DT – S3)	Да	Да	64,29 %

Примечание: составлена автором на основе полученных данных в ходе исследования.

Рис. 4. Динамика прогнозного риска и моменты возникновения сбоев
Примечание: составлен автором по результатам данного исследования

В качестве базового предиктора был обучен ансамбль на основе градиентного бустинга. Для оценки качества прогноза применялась не классическая метрика Ассигасу, которая искажается при дисбалансе классов, а событийно-ориентированная метрика Event Recall (полнота обнаружения событий). Для оценки качества классификатора при дисбалансе классов были проанализированы ROC-кривая и PR-кривая (Precision-Recall) (рис. 3), а также построена матрица ошибок (Confusion Matrix) (табл. 3), под-

тверждающие высокую разделяющую способность градиентного бустинга в рамках перекрестной проверки.

Модель продемонстрировала высокую прогнозирующую способность: при оптимально подобранном пороге тревоги ($\tau = 0,7$) алгоритм корректно идентифицировал 85,7 % предаварийных состояний до фактической остановки оборудования.

Полученная ML-модель была интегрирована в имитационную среду AnyLogic для сценарной оценки производственных

KPI [17, с. 210; 20, с. 84]. В ходе симуляции было проведено сравнительное тестирование двух базовых стратегий обслуживания:

1. Сценарий S0 (Реактивный): Моделировалась работа оборудования до возникновения физического отказа. В данном сценарии время восстановления включало в себя диагностику, ожидание запчастей и сложный ремонт. Суммарная доля времени простоя оборудования в базовом сценарии составила 16,8 % от общего фонда рабочего времени.

2. Сценарий S3 (Проактивный на базе ML): В агенты оборудования была внедрена логика прерывания работы. При достижении показателем Risk Score (вероятность сбоя) порога $\tau = 0,7$, станок автоматически переводился в режим превентивного обслуживания. Несмотря на увеличение количества кратковременных технических остановок, исключение тяжелых аварий позволило снизить суммарную долю простоя до 6,0 %.

Для обеспечения объективной количественной оценки предложенная гибридная архитектура была сопоставлена с альтернативными методами управления отказами. Результаты комплексного сравнения подходов по ключевым KPI представлены в табл. 4.

Визуализация работы предиктивного алгоритма в имитационной среде представлена на рис. 4. График демонстрирует динамику изменения прогнозного риска $R(t)$ на временной шкале: пересечение кривой риска с установленным порогом $\tau = 0,7$ инициирует сигнал тревоги заблаговременно до момента наступления фактического сбоя, что обеспечивает необходимое окно упреждения для проведения профилактических работ.




Рис. 5. Сравнение доли суммарного времени простоя оборудования по сценариям обслуживания
Примечание: составлен автором по результатам данного исследования

Сравнительный анализ сценариев (S0 и S3) в имитационной модели [12] технического обслуживания по ключевому показателю – доле непроизводительных простоев оборудования – наглядно представлен на рис. 5.

Как видно из представленных данных, интеграция машинного обучения в логику имитационной модели позволяет не просто выявлять аномалии, но и математически доказывать экономическую целесообразность перехода к проактивному обслуживанию: относительное сокращение времени непроизводительных простоев (при переходе от S0 к S3) составило 64,29 %.

Важным аспектом внедрения предложенной архитектуры является анализ чувствительности системы к ложным срабатываниям (False Alarms). Имитационное моделирование наглядно продемонстрировало, что снижение порога тревоги повышает частоту необоснованных остановок на профилактику. Использование цифрового двойника [6, с. 305; 21] позволяет руководству предприятия математически обосновать баланс между стоимостью ложной тревоги и стоимостью пропущенной аварии, подбирая порог τ под конкретные экономические условия производства.

Экономическая эффективность предложенного подхода подтверждается не только сокращением временных простоев, но и прямым снижением финансовых потерь. В рамках имитационной модели была интегрирована стоимостная функция, оценивающая финансовые последствия инцидентов.

$$C_{total} = N_{fail} \times C_{fail} + N_{prev} \times C_{prev}, \quad (3)$$

где N_{fail} – количество фактических аварийных остановок;

C_{fail} – стоимость устранения тяжелой аварии (включая ремонт и потери от простоя выпуска продукции);

N_{prev} – количество профилактических остановок (включая обоснованные и ложные срабатывания);

C_{prev} – стоимость плановой профилактики.

Для обеспечения репрезентативности финансовой модели были использованы базовые расчетные значения: $C_{fail} = 500\,000$ руб., $C_{prev} = 50\,000$ руб. (стоимость тяжелой аварии в 10 раз превышает стоимость плановой превентивной профилактики). В табл. 5 представлены результаты расчета экономической эффективности для валидационной тестовой выборки, в которой зафиксировано 1800 предаварийных состояний.

Таблица 5

Расчет совокупных эксплуатационных издержек
при различных стратегиях обслуживания

Статья затрат	Сценарий S0 (Реактивный)	Сценарий S3 (Проактивный, $\tau = 0,7$)
Количество фактических аварий N_{fail}	1800	257
Количество профилактических остановок N_{prev}	0	1743 (1543 TP + 200 FP)
Стоимость аварий	900 000 000 руб.	128 500 000 руб.
Стоимость профилактики	0 руб.	87 150 000 руб.
Совокупные эксплуатационные издержки C_{total}^1	900 000 000 руб.	215 650 000 руб.
Абсолютная экономия	–	684 350 000 руб.
Относительное снижение издержек	–	0,76

Примечание: составлена автором на основе полученных данных в ходе исследования.

Расчет производился из допущения, что стоимость тяжелой аварийной остановки (включающая дорогостоящий ремонт и потерю выпускаемой продукции) в среднем в 10–12 раз превышает стоимость плановой превентивной профилактики. Моделирование показало, что предотвращение критических аварий приводит к снижению совокупных эксплуатационных издержек предприятия на 684 350 000 руб., что соответствует экономии в 76,0 % по сравнению с реактивной стратегией обслуживания (S0). Таким образом, даже с учетом увеличения частоты сервисных вмешательств из-за ложных срабатываний алгоритма, абсолютная экономия полностью окупает затраты на внедрение системы.

Ключевые результаты проведенного исследования сводятся к следующему:

1. Разработана и верифицирована воспроизводимая методика подготовки гетерогенных производственных данных, исключая эффект «утечки» при построении предиктивных моделей.

2. Спроектирован и успешно обучен ансамбль алгоритмов машинного обучения на базе градиентного бустинга. Применение функции потерь, адаптированной под задачу, позволило достичь доли обнаруженных предаварийных событий (Event Recall) на уровне 85,7 %.

3. В среде AnyLogic построена имитационная модель (цифровой двойник), в которой смоделированы различные регламенты реагирования на сбои. Сценарий упреждающей профилактики (S3) математически доказал возможность снижения времени аварийного простоя оборудования на 64,29 % по сравнению с базовым сценарием работы до отказа.

Ограничения и масштабируемость предложенного метода

При интерпретации полученных результатов необходимо учитывать ряд ограничений предложенного системно-имитационного подхода. Во-первых, точность и чувствительность предиктивной ML-модели критически зависят от качества, полноты и дискретности собираемой аппаратной телеметрии. Наличие сильных электромагнитных шумов в сигналах датчиков на реальном производстве может потребовать внедрения дополнительных вычислительно-затратных фильтров Калмана или сглаживающих алгоритмов на этапе предварительной обработки [22]. Во-вторых, интеграция предиктора с цифровым двойником в режиме реального времени накладывает повышенные требования к вычислительным ресурсам; при масштабировании модели на сотни узлов оборудования потребуется оптимизация межсетевых запросов и переход на микро-сервисную архитектуру обмена данными. В-третьих, при естественном износе физических компонентов станков неизбежно возникает дрейф концепции (concept drift), что диктует необходимость регламентной рекалибровки и дообучения ансамблевой модели [23].

Рассматривая вопросы переносимости предложенной архитектуры на другие производственные линии, следует отметить, что методологический каркас является универсальным. Однако практическое внедрение на оборудовании иной номенклатуры потребует перенастройки ряда компонентов: сбора нового исторического датасета для переобучения алгоритмов градиентного бустинга, оптимизации гиперпараметров модели под новые паттерны отказов, а так-

же внесения структурных изменений в диаграммы состояний (Statecharts) оборудования в среде AnyLogic с учетом специфики логистики и регламентов конкретного цеха.

Заключение

В рамках проведенного исследования была успешно решена задача разработки системно-имитационного подхода к оценке эффективности предиктивных моделей на производстве. Научная новизна полученных результатов подтверждается созданием архитектуры сквозного моделирования, которая переводит оценку ML-алгоритмов из плоскости абстрактных метрик Data Science (Accuracy, F1-score) в плоскость прикладного системного анализа. Интеграция ансамблевых алгоритмов в среду AnyLogic позволила сформировать полноценный цифровой двойник производственной линии, динамически оценивающий экономические последствия предиктивных прогнозов.

Практическая значимость работы заключается в создании готовой основы для внедрения систем раннего предупреждения производственных сбоев. Предложенный инструментарий обеспечивает предприятиям возможность оценивать экономический эффект от ML-моделей до их физического внедрения посредством симуляции простоев и выпуска продукции в AnyLogic. В ходе экспериментов доказано, что при оптимальном подборе порога тревоги τ , обеспечивающем баланс между полнотой обнаружения (Event Recall) и частотой ложных срабатываний, система позволяет достичь значимого сокращения производственных простоев.

Результаты вычислительных экспериментов полностью подтвердили выдвинутую гипотезу о высокой эффективности проактивных стратегий технического обслуживания. Переход от базового сценария (работа оборудования до фактического отказа) к предиктивному регламенту (остановка при достижении порога риска) позволил снизить суммарное время производственных простоев на 64,29 %. Доказано, что для корректной оценки алгоритмов в условиях реального производства целесообразно использовать событийно-ориентированные метрики (Event Recall) и применять временное разделение выборки для предотвращения утечки данных.

Предложенная гибридная архитектура обладает высокой практической значимостью для высокотехнологичных предприятий, в том числе в сфере аддитивного производства и 3D-печати. Разработанный

инструментарий дает возможность руководству оценивать системный эффект от внедрения искусственного интеллекта и безопасно тестировать различные пороговые значения тревоги в виртуальной песочнице AnyLogic, не подвергая риску реальное оборудование.

В дальнейших исследованиях планируется расширить базу экспериментов за счет применения нейросетевых архитектур для анализа многомерных временных рядов (LSTM) и разработки модуля автоматического непрерывного переобучения предиктивных моделей на потоковых данных.

Список литературы

1. Боровков А. И., Рябов Ю. А. Цифровые двойники: определение, подходы и методы разработки // *Цифровая трансформация экономики и промышленности*. СПб.: СПбПУ, 2019. С. 234–245. URL: <https://cyberleninka.ru/article/n/tsifrovye-dvoyniki-v-upravlenie-zhiznennym-tsiklom-izdeliy-i-tehnologiy> (дата обращения: 29.06.2026). DOI: 10.18720/IEP/2019.3/25. EDN: ZUPIWC.
2. Давыдов И. Д. 3D технологии и искусственный интеллект - эпоха автоматизации // *Педагогика, психология и экономика: вызовы современности и тенденции развития*. М.: MMA, 2024. С. 15–22. URL: https://mmamos.ru/wp-content/uploads/science/pedagog-aspir_2024.pdf (дата обращения: 29.06.2026).
3. Савицкий О. М. Разработка интеллектуальной системы мониторинга и прогнозирования состояния горнодобывающего оборудования на основе технологий граничных вычислений и машинного обучения // *Научные исследования в области цифровых технологий*. Кемерово: КузГТУ, 2025. С. 31507.1–31507.4. URL: <https://elibrary.ru/item.asp?id=84077357> (дата обращения: 29.06.2026).
4. Хасты Т., Тибишани Р., Фридман Дж. Основы статистического обучения. Интеллектуальный анализ данных, логический вывод и прогнозирование. М.: Вильямс, 2020. 768 с. ISBN 978-5-907144-42-2.
5. Давыдов И. Д. Оптимизация уровня ошибок процессов 3D-печати и аддитивного производства при интеграции искусственного интеллекта // *Инженерный вестник Дона*. 2025. № 11. URL: <https://cyberleninka.ru/article/n/optimizatsiya-urovnya-oshibok-protseessov-3d-pechati-i-additivnogo-proizvodstva-pri-integratsii-iskusstvennogo-intellekta> (дата обращения: 29.06.2026).
6. Прохоров А., Лысачев М. Цифровой двойник. Анализ, тренды, мировой опыт. М.: АльянсПринт, 2020. 401 с. [Электронный ресурс]. URL: https://datafinder.ru/files/new4/digital_twin_book.pdf (дата обращения: 29.06.2026). ISBN 978-5-98094-008-9.
7. Ismail L., Abdelmoti A., Basu A., Berini A. D. E., Naouss M. A Systematic Review of Digital Twin-Driven Predictive Maintenance in Industrial Engineering: Taxonomy, Architectural Elements, and Future Research Directions. 2025. Art. 2509. 24443. DOI: 10.48550/arXiv.2509.24443.
8. Errandonea I., Beltrán S., Arrizabalaga S. Digital Twin for maintenance: A literature review // *Computers in Industry*. 2020. Vol. 123. Art. 103316. URL: <https://www.sciencedirect.com/science/article/pii/S016636152030118X> (дата обращения: 29.06.2026). DOI: 10.1016/j.compind.2020.103316.
9. Aheleroff S., Xu X., Zhong R. Y., Lu Y. Digital Twin as a Service (DTaaS) in Industry 4.0: an Architecture Reference Model // *Advanced Engineering Informatics*. 2021. Vol. 47. Art. 101225. URL: <https://www.sciencedirect.com/science/article/pii/S147403462030232X> (дата обращения: 29.06.2026). DOI: 10.1016/j.aei.2020.101225.

10. Гусев П. Ю., Таволжанский А. В. Алгоритмизация обработки и подготовки данных для построения моделей предиктивной аналитики // Вестник ВГТУ. 2024. Т. 20. № 2. С. 14–19. URL: <https://cyberleninka.ru/article/n/algoritmizatsiya-obrabotki-i-podgotovki-dannyh-dlya-postroeniya-modeley-prediktivnoy-analitiki> (дата обращения: 29.06.2026). DOI: 10.36622/1729-6501.2024.20.2.002.
11. Дьяконов А. Г. Машинное обучение и анализ данных (курс лекций) [Электронный ресурс] // GitHub. 2024. URL: https://github.com/Dyakonov/MLDM_BOOK (дата обращения: 29.06.2026).
12. Кормин Т. Г., Царицон Н. И., Тихонов И. Н., Хирнов С. А. Применение имитационного моделирования при вводе в эксплуатацию производственной линии // Вестник ПНИПУ. 2025. № 53. С. 88–110. URL: <https://cyberleninka.ru/article/n/primenenie-imitatsionnogo-modelirovaniya-pri-vvode-v-ekspluatatsiyu-proizvodstvennoy-linii> (дата обращения: 29.06.2026). DOI: 10.15593/2224-9397/2025.1.05.
13. Абдулнагимов А. И., Агеев Г. К. Нейросетевые технологии в полунатурном моделировании: принципы реализации цифровых двойников ГТД // Вестник УГАТУ. 2019. Т. 23. № 4 (86). С. 115–121. URL: <https://cyberleninka.ru/article/n/neyrosetevye-tehnologii-v-polunaturnom-modelirovanii-printsipy-realizatsii-tsifrovyyh-dvoynikov-gtd> (дата обращения: 09.07.2026).
14. Неупокоева Е. О., Быстров В. В., Шишаев М. Г. Гибридная технология синтеза транспортно-логистических систем на основе машинного обучения и имитационного моделирования // Экономика. Информатика. 2024. Т. 51. № 3. С. 670–681. URL: <https://cyberleninka.ru/article/n/gibridnaya-tehnologiya-sinteza-transportno-logisticheskikh-sistem-na-osnove-mashinnogo-obucheniya-i-imitatsionnogo-modelirovaniya> (дата обращения: 29.06.2026). DOI: 10.52575/2687-0932-2024-51-3-670-681.
15. Добренко Н. В., Бабан В. Ю., Чернышева А. В., Говоров А. И. Разработка интегрированной панели управления жизненным циклом моделей машинного обучения для ИТ-организаций с распределенной инфраструктурой // Экономика. Право. Инновации. 2025. Т. 13. № 4. С. 83–100. URL: <https://cyberleninka.ru/article/n/razrabotka-integrirovannoy-paneli-upravleniya-zhiznennym-tsiklom-modeley-mashinnogo-obucheniya-dlya-it-organizatsiy-s> (дата обращения: 29.06.2026). DOI: 10.17586/2713-1874-2025-4-83-100.
16. Давыдов И. Д. Исходный код и модели машинного обучения для системы предиктивного обслуживания (DT-driven PdM) [Электронный ресурс] // GitHub. [Электронный ресурс]. URL: <https://github.com/Bibabus/predictive-maintenance-ml> (дата обращения: 28.06.2026).
17. Акопов А. С. Имитационное моделирование: учебник и практикум для вузов. М.: Юрайт, 2020. 389 с. EDN: KJJXUP. ISBN 978-5-534-02528-6.
18. Борщев А. В. Практическое агентное моделирование и его место в арсенале аналитика // Exponenta Pro. 2004. № 3–4. С. 38–47. URL: <http://simulation.su/uploads/files/default/borchhev.pdf> (дата обращения: 29.06.2026).
19. Culligan L. Bosch Production Line Performance [Электронный ресурс] // GitHub. [Электронный ресурс]. URL: <https://github.com/liamculligan/bosch-production-line-performance> (дата обращения: 25.06.2026).
20. Лычкина Н. Н. Имитационное моделирование экономических процессов. М. ИНФРА-М, 2024. 254 с. [Электронный ресурс]. URL: <https://znanium.ru/read?id=431111> (дата обращения: 29.06.2026). DOI: 10.12737/724. ISBN 978-5-16-018933-8.
21. Каримов А. И., Хафизов А. Р. Цифровой двойник как основа самообучающейся системы предсказательного обслуживания в строительстве // Наука молодых – инновационному развитию АПК в обеспечении продовольственной безопасности Российской Федерации: материалы Всероссийской (национальной) научно-практической конференции молодых ученых (г. Уфа, 26 ноября 2025 г.). Уфа: БГАУ, 2025. С. 175–180. [Электронный ресурс]. URL: <https://www.elibrary.ru/item.asp?id=89168160> (дата обращения: 29.06.2026).
22. Welch G., Bishop G. An Introduction to the Kalman Filter // University of North Carolina at Chapel Hill, Department of Computer Science. 1995. TR 95-041. [Электронный ресурс]. URL: https://www.cs.cmu.edu/~motionplanning/papers/sbp_papers/kalman/welch_intro_kalman.pdf (дата обращения: 07.07.2026).
23. Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia H. A survey on concept drift adaptation // ACM Computing Surveys (CSUR). 2014. Vol. 46. Is. 4. P. 1–37. URL: https://www.researchgate.net/publication/261961254_A_Survey_on_Concept_Drift_Adaptation (дата обращения: 07.07.2026). DOI: 10.1145/2523813.

Конфликт интересов: Автор заявляет об отсутствии конфликта интересов.

Conflict of interest: The author declares that there is no conflict of interest.

Финансирование: Автор заявляет об отсутствии внешнего финансирования.

Financing: The research was performed without external funding.