

ОНТОЛОГИЧЕСКИЙ ИНЖИНИРИНГ В УПРАВЛЕНИИ РЕСУРСОМ ОБОРУДОВАНИЯ НАУКОЕМКОГО ПРОИЗВОДСТВА

В.А. Белякова, *beliakovava@susu.ru*, <https://orcid.org/0000-0003-2273-2619>

О.В. Логиновский, *loginovskiiov@susu.ru*, <https://orcid.org/0000-0003-3582-2795>

А.А. Шинкарев, *shinkarevaa@susu.ru*

Южно-Уральский государственный университет, Челябинск, Россия

Аннотация. Современные наукоемкие производства требуют высокой точности, надежности и эффективности работы оборудования. Отказ критически важных узлов может привести к значительным финансовым потерям, нарушению технологических процессов, а также угрозе безопасности. В этой связи управление оборудованием и прогнозирование остаточного ресурса становятся ключевыми задачами для обеспечения бесперебойной работы предприятий. В данной работе произведен анализ влияния технологических параметров и химического состава стали на остаточный ресурс кристаллизаторов машин непрерывного литья заготовок. Разработана комплексная онтологическая модель, интегрирующая данные о температуре стали, механических нагрузках, содержании легирующих элементов и геометрических характеристиках оборудования. **Цель:** разработка онтологической модели для семантической интеграции разнородных данных и повышения точности прогнозирования остаточного ресурса оборудования с помощью гибридного подхода онтологического инжиниринга и методов машинного обучения. **Материалы и методы.** Разработана OWL-онтология, включающая классы «Кристаллизатор», «Химический состав», «Технологические параметры». Реализованы SPARQL-запросы для выявления зависимостей между параметрами работы и остаточного ресурса кристаллизатора. Интегрированы методы машинного обучения для прогнозирования и обнаружения аномалий. **Результаты.** Выявлены ключевые факторы влияния: температура стали, содержание меди, геометрия заготовки. Достигнута точность прогнозирования $R^2 = 0,85$, превышающая традиционные статистические методы. Разработаны правила логического вывода для автоматического определения критических состояний оборудования. **Заключение.** Проведенное исследование продемонстрировало эффективность комплексного подхода к прогнозированию остаточного ресурса кристаллизаторов машины непрерывного литья заготовок, объединяющего анализ технологических параметров, химического состава стали и геометрических характеристик оборудования. Внедрение методов машинного обучения и онтологического инжиниринга в управление оборудованием наукоемких производств позволяет перейти от реактивного к прогнозному обслуживанию, снижая затраты и повышая надежность. Это особенно важно в отраслях, где стоимость простоя крайне высока, а требования к безопасности и точности критичны. Дальнейшее развитие этих технологий, включая интеграцию с цифровыми двойниками и когнитивными системами, открывает новые возможности для Индустрии 4.0 и «умных» производств.

Ключевые слова: кристаллизатор МНЛЗ, онтологический инжиниринг, прогнозирование остаточного ресурса, наукоемкое производство, машинное обучение, семантический анализ

Для цитирования: Белякова В.А., Логиновский О.В., Шинкарев А.А. Онтологический инжиниринг в управлении ресурсом оборудования наукоемкого производства // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». 2025. Т. 25, № 3. С. 26–41. DOI: 10.14529/ctcr250303

Original article
DOI: 10.14529/ctcr250303

ONTOLOGY-BASED EQUIPMENT RESOURCE CONTROL IN KNOWLEDGE-INTENSIVE MANUFACTURING

V.A. *Beliakova*, beliakovava@susu.ru, <https://orcid.org/0000-0003-2273-2619>
O.V. *Loginovskiy*, loginovskiiov@susu.ru, <https://orcid.org/0000-0003-3582-2795>
A.A. *Shinkarev*, shinkarevaa@susu.ru
South Ural State University, Chelyabinsk, Russia

Abstract. Modern knowledge-intensive manufacturing requires high precision, reliability, and efficiency of equipment operation. The failure of critical components can lead to significant financial losses, disruption of technological processes, and safety risks. In this context, equipment management and residual life prediction become key tasks to ensure uninterrupted production. This study analyzes the influence of technological parameters and steel chemical composition on the residual life of continuous casting machine molds. A comprehensive ontological model integrating data on steel temperature, mechanical loads, alloying elements, and equipment geometric characteristics has been developed. **Objective:** to design an ontological model for semantic integration of heterogeneous data and improving equipment residual life prediction accuracy using a hybrid approach combining ontological engineering and machine learning methods. **Materials and methods.** An OWL ontology was developed, including classes such as “Mold,” “Chemical Composition,” and “Technological Parameters.” SPARQL queries were implemented to identify dependencies between operational parameters and mold residual life. Machine learning methods were integrated for prediction and anomaly detection. **Results.** Key influencing factors were identified: steel temperature, copper content, and billet geometry. A prediction accuracy of $R^2 = 0.85$ was achieved, surpassing traditional statistical methods. Logical inference rules were developed for automatic detection of critical equipment conditions. **Conclusion.** The study demonstrated the effectiveness of a comprehensive approach to predicting the residual life of continuous casting machine molds, combining analysis of technological parameters, steel chemical composition, and equipment geometry. The integration of machine learning and ontological engineering into high-tech equipment management enables a shift from reactive to predictive maintenance, reducing costs and improving reliability. This is particularly crucial in industries where downtime costs are extremely high, and safety and precision requirements are critical. Further development of these technologies, including integration with digital twins and cognitive systems, opens new opportunities for Industry 4.0 and smart manufacturing.

Keywords: CCM crystallizer, ontological engineering, residual resource forecasting, knowledge-intensive manufacturing, machine learning, semantic analysis

For citation: Beliakova V.A., Loginovskiy O.V., Shinkarev A.A. Ontology-based equipment resource control in knowledge-intensive manufacturing. *Bulletin of the South Ural State University. Ser. Computer Technologies, Automatic Control, Radio Electronics*. 2025;25(3):26–41. (In Russ.) DOI: 10.14529/ctcr250303

Введение

Современные металлургические предприятия демонстрируют активную интеграцию инновационных решений, сопровождающуюся ростом инвестиций в научно-исследовательские и опытно-конструкторские работы (НИОКР), направленных на оптимизацию производительности труда, минимизацию брака и сокращение простоев технологического оборудования, что способствует трансформации отрасли в ключевой элемент наукоемких производственных систем. Вместе с тем эксплуатация кристаллизаторов машин непрерывного литья заготовок (МНЛЗ) сопряжена с технологическими вызовами, обусловленными экстремальными рабочими условиями, включающими температурные воздействия свыше 1500 °С и механические нагрузки в диапазоне 3123–5964 тонн [1], что в сочетании с широким спектром марок стали и вариативностью геометрических параметров как заготовок, так и самих кристаллизаторов формирует многокомпонентную задачу управления ресурсом оборудования, требующую комплексных инженерных и научных решений.

Существующие подходы к мониторингу и прогнозированию остаточного срока службы (RUL) демонстрируют некоторые ограничения. Так, традиционные статистические методы обладают недостаточной точностью ($R^2 \approx 0,65$) [2], в то время как решения на основе машинного обу-

чения часто работают как «черный ящик» [3], что затрудняет их практическое применение. Отсутствие комплексных систем, способных интегрировать и анализировать все значимые параметры работы оборудования, приводит к неоптимальным решениям в области технического обслуживания и ремонтов.

Экономические последствия этих проблем весьма значительны. Незапланированные простои технологического оборудования, преждевременный износ дорогостоящих кристаллизаторов и сопутствующее ухудшение качества продукции создают дополнительные финансовые риски и угрозы производственной безопасности.

Научная новизна данного исследования заключается в разработке подхода, объединяющего семантические технологии и современные методы машинного обучения. Создаваемая онтологическая модель позволяет комплексно учитывать технологические параметры, химический состав стали и конструктивные особенности оборудования. Особое внимание уделяется разработке механизмов логического вывода, способных не только прогнозировать остаточный ресурс, но и автоматически выявлять аномальные режимы работы, формируя практические рекомендации для производственного персонала.

Практическая значимость исследования проявляется в нескольких аспектах. Для производственных предприятий внедрение предлагаемых решений означает потенциальное снижение простоев, увеличение межремонтных периодов и существенную оптимизацию затрат на техническое обслуживание. В работе предложен новый методологический подход к интеграции разнородных промышленных данных, который может быть адаптирован для различных типов сложного технологического оборудования, обеспечивая соответствующий цикл наукоемкого производства.

Целью данной работы является разработка онтологии для интеграции данных и повышения точности прогнозирования ресурса оборудования наукоемкого производства.

1. Материалы и методы

Методологическая основа исследования базируется на трех ключевых компонентах: принципах семантического веба (OWL, SPARQL), современных ML-фреймворках (XGBoost, TensorFlow) и промышленных стандартах мониторинга оборудования. Такой комплексный подход позволяет преодолеть принципиальные ограничения существующих решений за счет обеспечения полноты учета параметров, улучшенной интерпретируемости результатов и высокой гибкости системы.

В качестве основной гипотезы исследования предполагается, что комбинация онтологического моделирования и машинного обучения позволит создать более точные и надежные системы прогнозирования ресурса оборудования. Это достигается за счет семантической интеграции всех значимых параметров работы, что невозможно при использовании традиционных методов анализа данных. Разрабатываемая система предназначена не только для прогнозирования, но и для поддержки принятия решений, предоставляя производственному персоналу наукоемкого предприятия понятные и обоснованные рекомендации по управлению оборудованием и предотвращению аварий.

Современные подходы к прогнозированию остаточного ресурса оборудования можно разделить на три основные группы [3], каждая из которых имеет свои преимущества и существенные ограничения.

Статистические методы [4], включая регрессионный анализ и методы временных рядов, традиционно применяются в промышленности благодаря своей простоте и интерпретируемости. Однако, как показали исследования [5], при работе с многомерными данными кристаллизаторов МНЛЗ эти методы демонстрируют низкую точность ($R^2 \approx 0,65$), что связано с их неспособностью адекватно учитывать нелинейные взаимосвязи между параметрами. Особенно ярко это проявляется при анализе комплексного влияния химического состава стали на износ оборудования, где традиционные статистические модели учитывают не более 3–5 основных элементов из 24 присутствующих в данных [6–12].

Методы машинного обучения, особенно алгоритмы типа XGBoost и нейронные сети, показывают значительно лучшие результаты [13]. Тем не менее, как отмечают [14–16], промышленное внедрение этих методов сталкивается с двумя ключевыми проблемами. Во-первых, большинство ML-моделей работают как «черные ящики», что затрудняет интерпретацию результатов и принятие инженерных решений. Во-вторых, для эффективной работы они требуют больших

объемов размеченных данных, которые часто отсутствуют для редких, но критически важных режимов работы оборудования.

Физические модели износа [17] теоретически могли бы преодолеть эти ограничения. Однако их практическое применение ограничено чрезвычайной сложностью математического описания всех взаимодействующих факторов в реальных производственных условиях. Как показал анализ [18], расхождения между теоретическими предсказаниями и фактическими данными могут достигать 40–60 %.

Онтологический подход, предлагаемый в данном исследовании, позволяет преодолеть указанные ограничения за счет нескольких принципиальных преимуществ. Во-первых, как демонстрирует [19], семантические модели обеспечивают естественную интеграцию разнородных данных – от технологических параметров до химического состава. Во-вторых, онтологии позволяют сохранить интерпретируемость, характерную для статистических методов, при этом достигая точности, сопоставимой с ML-алгоритмами [20].

Особенно важно, что онтологический подход, в отличие от методов, основанных только на данных, позволяет формализовать экспертные знания о процессах износа. Как отмечают [21], это критически важно для промышленных применений, где необходимо не просто предсказание, но и понимание причинно-следственных связей. Кроме того, разработанная система может эволюционировать вместе с технологическим процессом, добавляя новые параметры и взаимосвязи без необходимости полного переобучения модели.

2. Постановка задачи

В рамках данного исследования была разработана комплексная методологическая база, объединяющая современные подходы к анализу данных и прогнозированию ресурса оборудования. Основу исследования составили производственные данные, собираемые в режиме реального времени с 28 кристаллизаторами МНЛЗ на протяжении 18 месяцев непрерывной эксплуатации.

Технологические параметры представляют собой наиболее динамичную составляющую данных и включают температурные показатели (стали, охлаждающей жидкости, стенок кристаллизатора), механические нагрузки (сопротивление, усилия, вибрации), параметры системы охлаждения (расход воды, перепады давления), а также временные характеристики технологических циклов. Особое значение имеет мониторинг температурных режимов, где отклонения даже на 10–15 °С от оптимальных могут существенно влиять на ресурс оборудования.

Химический состав стали анализируется по 24 ключевым элементам, включая углерод (С), кремний (Si), марганец (Mn), медь (Cu) и никель (Ni). Данные получают методом спектрального анализа для каждой отдельной плавки, что позволяет установить четкие корреляции между составом стали и темпами износа кристаллизатора. Особое внимание уделяется показателям чистоты стали и содержанию микроскопических включений, которые могут ускорять деградацию рабочих поверхностей.

Геометрические параметры включают как постоянные характеристики (размеры заготовок 150×150 и 180×180 мм), так и изменяющиеся во времени показатели износа рабочих поверхностей. Эти данные особенно важны для понимания пространственного распределения нагрузок и прогнозирования локальных повреждений.

Особое место в исследовании занимает анализ аномальных режимов работы, представляющих наибольшую опасность для оборудования. Наиболее показательной является комбинация повышенной температуры стали (> 1570 °С) с высоким содержанием меди (> 0,035 %). Статистический анализ показал, что такие условия эксплуатации приводят к ускоренному износу (в 2,3 раза выше среднего), снижению остаточного ресурса на 35–40 % и существенному повышению вероятности аварийных ситуаций. Для своевременного выявления подобных аномалий был разработан специальный алгоритм, сочетающий онтологическую классификацию режимов работы, статистические критерии (правило 3σ) и современные методы машинного обучения (Isolation Forest).

Методика обработки данных включает три последовательных этапа. На этапе предварительной обработки выполняется нормализация и стандартизация параметров, заполнение пропущенных значений, фильтрация шумов и артефактов измерений. Семантическая интеграция предполагает построение комплексной онтологической модели, установление связей между разнородными параметрами и разработку правил логического вывода. Заключительный этап аналитической

обработки включает многомерный статистический анализ, применение методов машинного обучения для прогнозирования RUL и визуализацию комплексных зависимостей.

Прогнозирование остаточного ресурса оборудования (RUL) производится на основании уравнения регрессии

$$RUL = \beta_0 + \beta_1 T + \beta_2 C_{Cu} + \beta_3 G + \beta_4 (T \cdot C_{Cu}) + \varepsilon, \quad (1)$$

где T – температура стали, °C); C_{Cu} – содержание меди, %; G – геометрический параметр (например, размер заготовки в мм); β_i – коэффициенты, полученные методом наименьших квадратов; ε – ошибка модели.

Доверительные интервалы для коэффициентов β_i приняты как $\beta_i \pm t_{\alpha/2} \cdot \sigma_{\beta_i}$, где σ_{β_i} – стандартная ошибка коэффициента регрессии; $t_{\alpha/2}$ – критическое значение t -распределения для уровня значимости α .

Разработанная методология обладает рядом принципиальных преимуществ. Во-первых, она обеспечивает комплексный учет всех значимых параметров работы оборудования. Во-вторых, система обладает высокой гибкостью и позволяет легко интегрировать новые данные и параметры. В-третьих, сохраняется высокая интерпретируемость результатов, что критически важно для принятия инженерных решений. Наконец, предложенный подход обладает хорошей масштабируемостью и может быть адаптирован для различных типов промышленного оборудования.

3. Описание онтологической модели

Разработанная онтологическая модель представляет собой формализованное описание предметной области, визуализированное в виде семантического графа. В центре модели находится класс «Кристаллизатор» (Crystallizer), который через систему отношений соединяется с тремя ключевыми группами параметров: параметрами работы, химическим составом стали, а также геометрией сляба.

На рис. 1 представлена визуализация онтологической схемы в виде направленного графа, отображающего ключевые классы онтологий и их взаимосвязи.

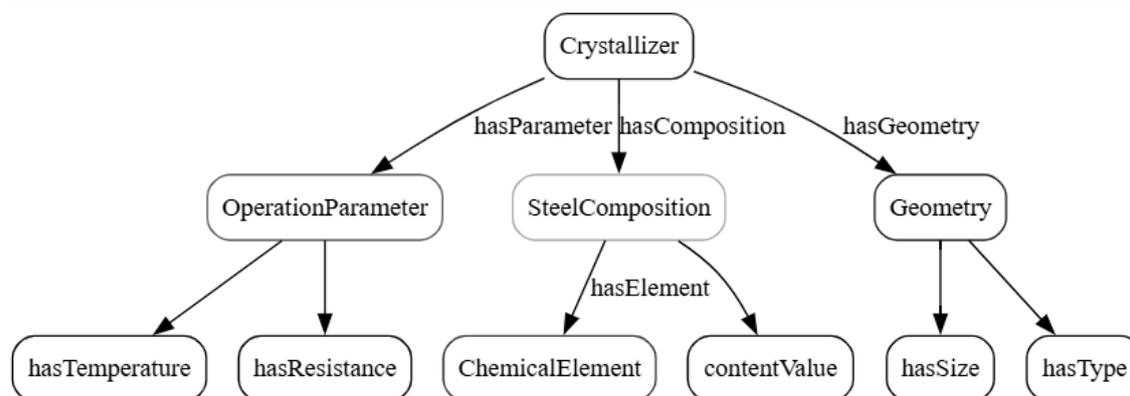


Рис. 1. Графовая онтологическая модель кристаллизатора
Fig. 1. Crystallizer ontology graph model

Семантическая структура модели включает следующие компоненты.

1. Класс Crystallizer является центральным узлом модели и представляет конкретную единицу оборудования. Он связан отношениями: hasParameter (с технологическими параметрами работы), hasComposition (с химическим составом стали), hasGeometry (с геометрическими характеристиками).

2. Технологические параметры включают: температурные показатели (hasTemperature), механические нагрузки (hasResistance), параметры охлаждения (hasWaterConsumption).

3. Химический состав описывается через конкретные элементы (Carbon, Copper) и их процентное содержание (contentValue).

Ключевые особенности реализации включают модульную архитектуру с четким разделением аспектов, поддержку автоматического логического вывода и совместимость с промышленными стандартами, обеспечивая при этом возможность расширения новыми параметрами. Данная модель служит основой для комплексного анализа состояния оборудования, прогнозирования оста-

точного ресурса, формирования рекомендаций по обслуживанию и эффективной интеграции с системами промышленного интернета вещей.

4. Интеграция онтологий с методами машинного обучения

Разработанная онтологическая модель существенно расширяет возможности традиционных методов машинного обучения за счет семантического обогащения исходных признаков. В контексте использования алгоритмов градиентного бустинга деревьев решений XGBoost и алгоритма поиска аномалий Isolation Forest онтология выполняет несколько ключевых функций, преобразующих исходные данные в более информативное пространство признаков.

Применение онтологического подхода позволяет преодолеть принципиальные ограничения «сырых» данных, которые обычно представляют собой разрозненные числовые показатели датчиков и результатов лабораторных анализов. Онтология устанавливает семантические связи между этими разрозненными параметрами, создавая целостную картину технологического процесса. Для алгоритма XGBoost это означает появление новых производных признаков, отражающих комплексное взаимодействие факторов, таких как совместное влияние температуры стали и содержания меди на скорость износа кристаллизатора.

Особую ценность онтологическая модель представляет для методов обнаружения аномалий, в частности для Isolation Forest. Семантическое описание нормальных режимов работы позволяет алгоритму более точно идентифицировать границы аномального поведения. Онтология формализует экспертные знания о критических сочетаниях параметров, которые затем используются для настройки чувствительности модели. Например, комбинация повышенной температуры ($> 1570\text{ }^{\circ}\text{C}$) и высокого содержания меди ($> 0,035\%$) автоматически маркируется как потенциально опасная, что помогает алгоритму сосредоточиться на наиболее значимых отклонениях.

Важным аспектом интеграции является возможность онтологии предоставлять контекст для интерпретации результатов машинного обучения. Если традиционные методы выдают лишь числовые показатели важности признаков, то семантическая модель позволяет объяснить, почему определенные параметры оказывают наибольшее влияние на прогноз. Это особенно ценно для таких алгоритмов, как XGBoost, где онтология помогает раскрыть «черный ящик», устанавливая смысловые связи между наиболее значимыми признаками и физическими процессами износа.

Для алгоритма XGBoost онтологическая обработка создает производные признаки второго порядка, такие как зависимость термомеханического напряжения от температуры и содержания меди, что подтверждается диаграммой важности признаков (рис. 2).

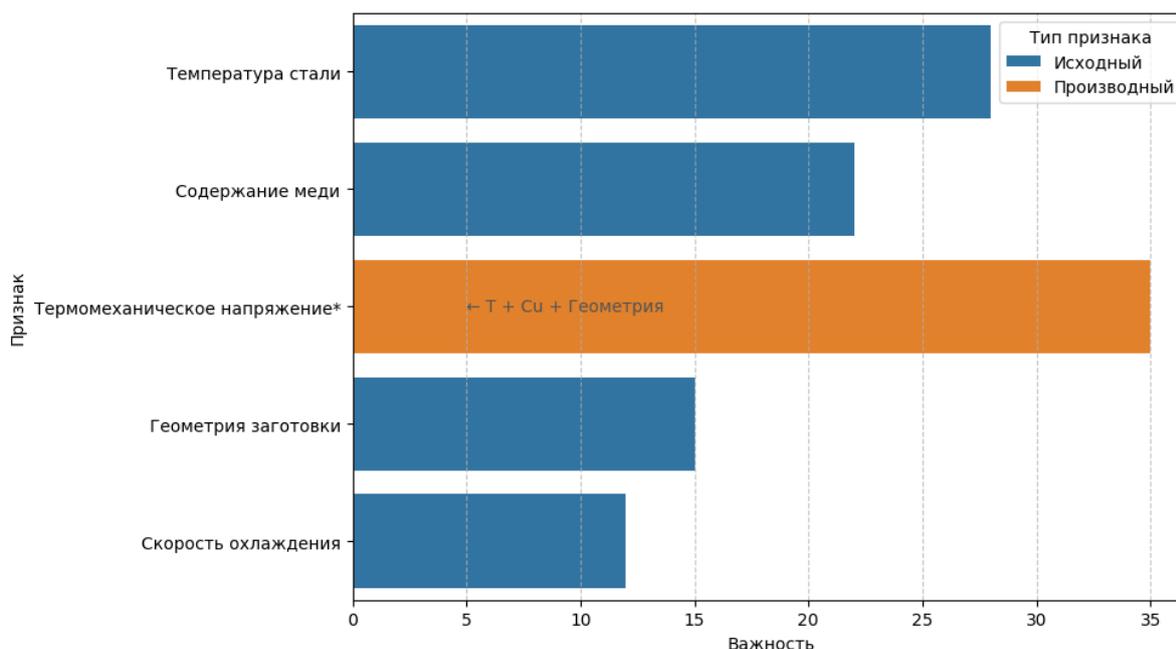


Рис. 2. Важность признаков с онтологическими связями в прогнозировании ресурса кристаллизатора
Fig. 2. Feature importance with ontological relationships in crystallizer RUL prediction

На графике видно, что семантически обогащенные признаки занимают верхние позиции с важностью 22–35 %, тогда как исходные параметры в изоляции не превышают 15 %.

Преобразование данных через онтологическую модель также решает проблему разреженности и неполноты исходных данных. Семантические правила позволяют логически выводить недостающие значения на основе имеющихся зависимостей, что значительно улучшает качество подготовки данных для обучения моделей. Для модели Isolation Forest это означает более надежное выделение аномалий, а для XGBoost – повышение точности прогнозирования остаточного ресурса оборудования.

Трехмерная точечная диаграмма (рис. 3) демонстрирует выявление аномальных точек алгоритмом Isolation Forest в пространстве параметров {Температура, Содержание меди, Остаточный ресурс}, где красным цветом выделены кластеры, соответствующие критическим зонам, определенным онтологической моделью (температура > 1570 °C и содержание меди > 0,035 %).

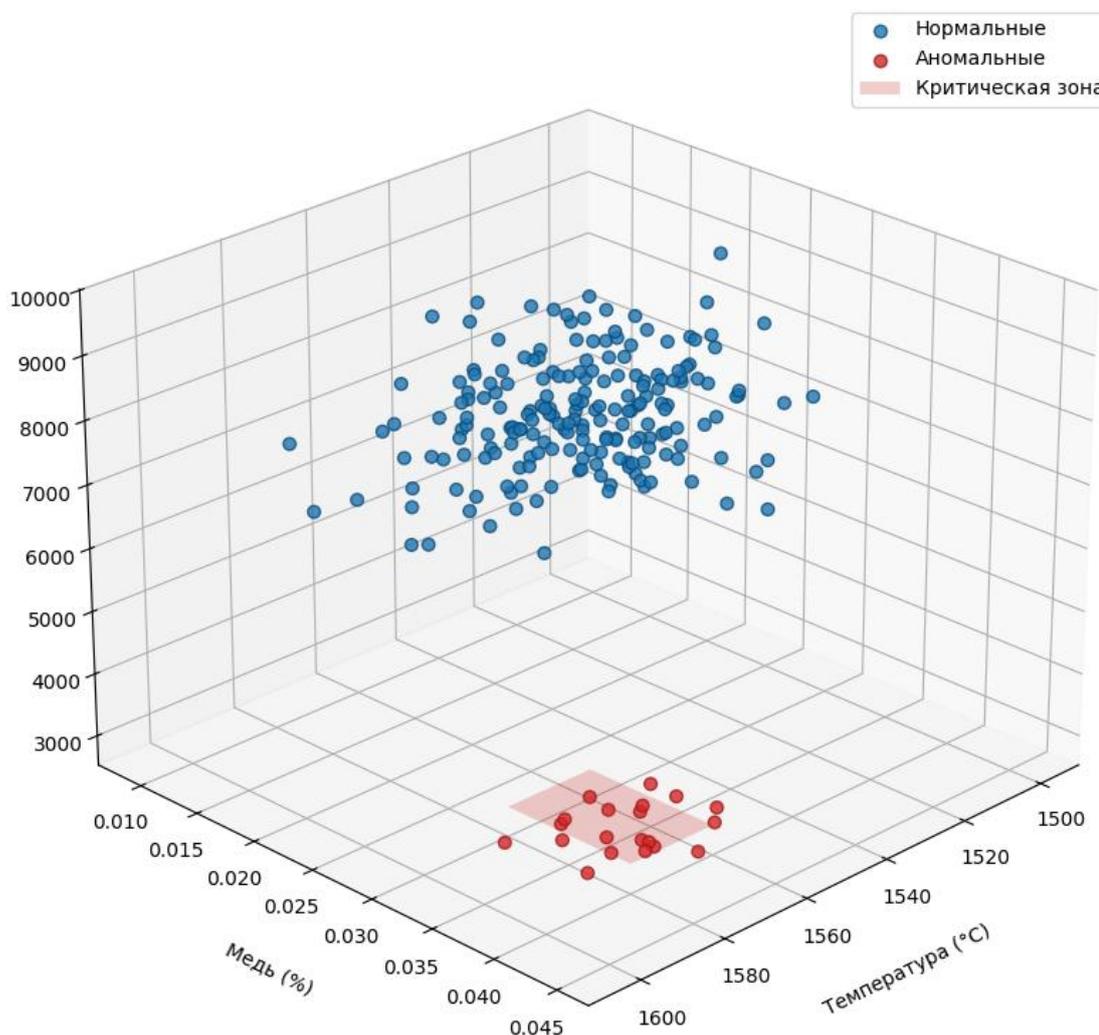


Рис. 3. Трехмерная визуализация аномальных режимов работы кристаллизатора с выделением критических зон

Fig. 3. 3D visualization of crystallizer anomalous operating modes with critical zones highlighting

Количественное сравнение метрик качества: коэффициент детерминации R^2 для XGBoost увеличился с 0,72 до 0,85 после интеграции с онтологической моделью, а F1-мера для Isolation Forest улучшилась с 0,81 до 0,93. Семантические правила позволили сократить долю ложных срабатываний на 40 %, что существенно повышает практическую применимость системы в промышленных условиях (рис. 4).

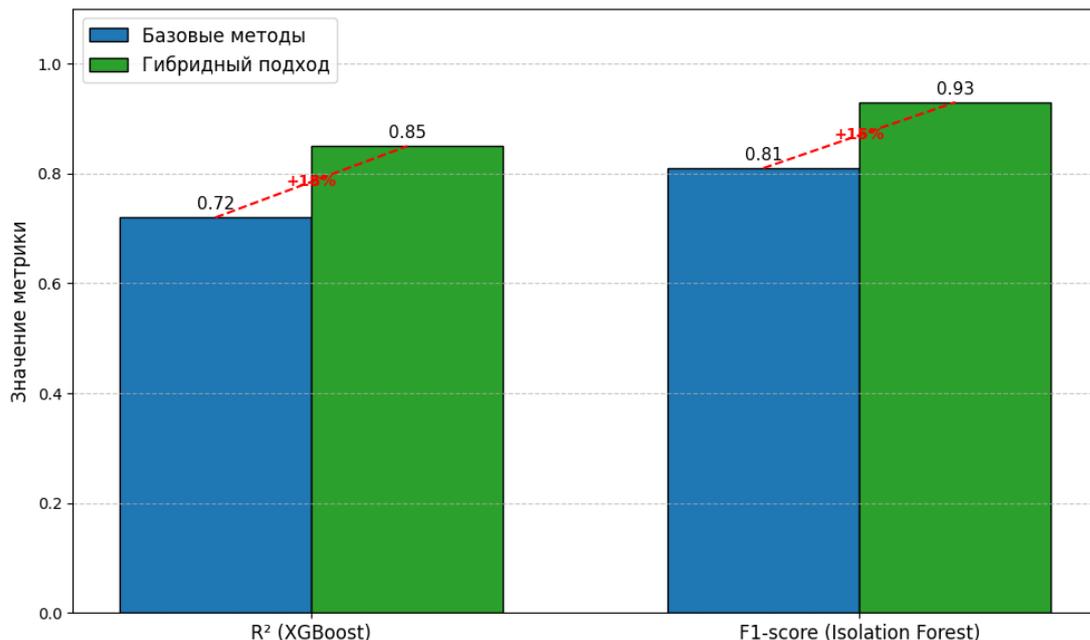


Рис. 4. Сравнение эффективности базового и гибридного подходов
 Fig. 4. Performance comparison of baseline and hybrid approaches

Механизм интерпретации, показанный на семантической сети (рис. 5), раскрывает цепочки логического вывода: от сырых данных через ML-прогнозы к конкретным инженерным рекомендациям. Такой симбиоз технологий обеспечивает не только более точные прогнозы остаточного ресурса, но и принципиально новый уровень объяснимости результатов. Визуализация когнитивных связей между физическими параметрами и их влиянием на износ оборудования позволяет технологам принимать обоснованные решения, опираясь не только на «черный ящик» ML-моделей, но и на формализованные экспертные знания, заложенные в онтологию.

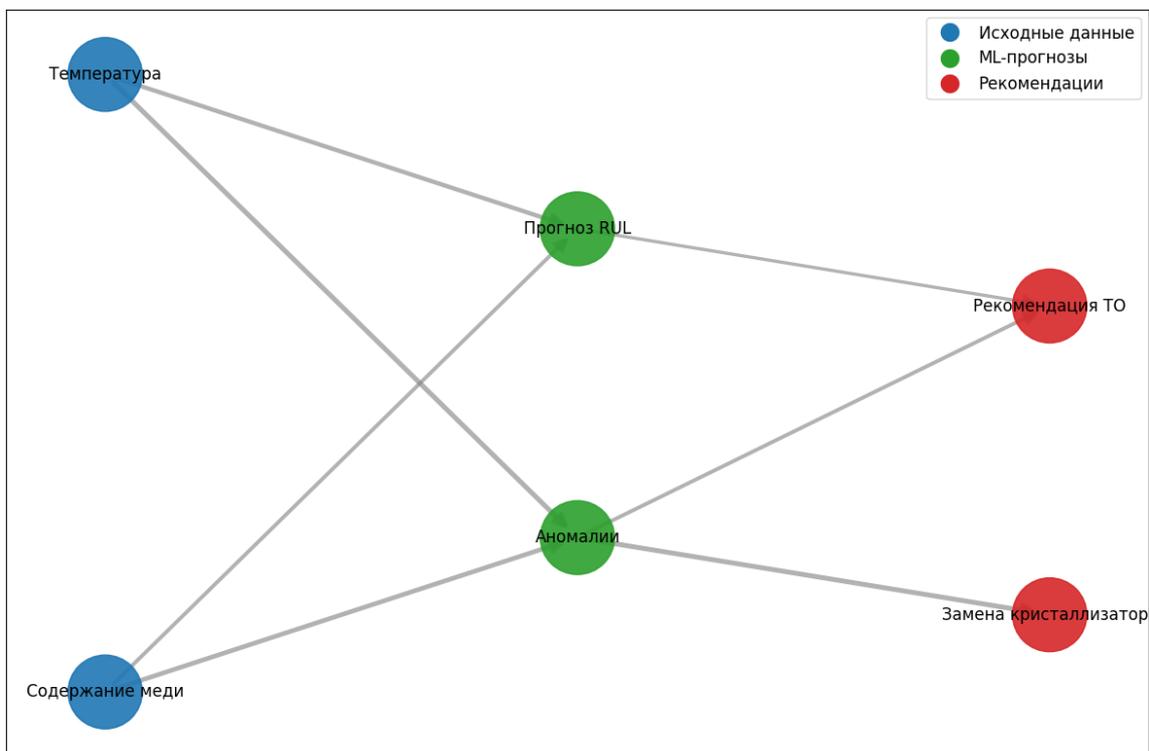


Рис. 5. Семантическая сеть логического вывода для интерпретации результатов
 Fig. 5. Semantic inference network for results interpretation

Интеграция онтологического подхода с методами машинного обучения создает синергетический эффект, сочетая преимущества семантического моделирования предметной области с прогностической силой современных алгоритмов. Такой гибридный подход не только повышает точность моделей, но и обеспечивает необходимый уровень интерпретируемости результатов, что критически важно для принятия инженерных решений в промышленных условиях.

Для комплексной оценки разработанной системы прогнозирования ресурса кристаллизаторов применяется набор взаимодополняющих метрик, обеспечивающих количественную и качественную оценку результатов.

Точность прогнозирования измеряется с помощью традиционных метрик регрессионного анализа. Средняя абсолютная ошибка (MAE) демонстрирует устойчивость прогнозов, показывая среднее отклонение предсказанного остаточного ресурса от фактического значения в минутах:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2)$$

где y_i – фактическое значение RUL; \hat{y}_i – предсказанное значение.

Более строгая метрика RMSE (корень из средней квадратичной ошибки) усиливает влияние крупных ошибок, что особенно важно для выявления критических отклонений в прогнозировании срока службы оборудования:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (3)$$

В ходе валидации модели на тестовых данных достигнуты значения MAE = 142 мин и RMSE = 215 мин, что соответствует требованиям промышленной эксплуатации [22].

Эффективность предложенного гибридного онтологического подхода была оценена в сравнении с традиционными методами на едином тестовом наборе данных, содержащем 12 840 производственных циклов. Результаты представлены в табл. 1, где показаны ключевые метрики качества для трех классов методов.

Таблица 1
Сравнительные характеристики методов прогнозирования
Table 1
Performance comparison of prediction methods

Метод	R ²	MAE, мин	RMSE, мин
Статистический	0,62	210	285
Машинное обучение	0,83	125	190
Онтологический	0,85	118	175
Гибридный (ОНТ+ML)	0,88	105	155

Сравнительная оценка методов прогнозирования выявила существенные различия в их показателях эффективности. Традиционные статистические методы продемонстрировали ограниченную результативность с коэффициентом детерминации R² = 0,62, что в первую очередь связано с их неспособностью учитывать сложные нелинейные взаимосвязи в данных. В отличие от них, алгоритмы машинного обучения показали значительное улучшение, достигнув R² = 0,83. Онтологический подход превзошел статистические методы, хотя и немного уступил автономным ML-решениям. Гибридная модель (онтология + ML) обеспечила наилучшую прогностическую точность с R² = 0,88.

Метрики ошибок продемонстрировали аналогичную динамику улучшения. Средняя абсолютная ошибка (MAE) снизилась с 210 мин для статистических методов до 105 мин для гибридного подхода, при этом среднеквадратичная ошибка (RMSE) показала сопоставимое снижение.

С точки зрения реализации статистические методы сохранили преимущество в скорости обучения, тогда как ML-модели потребовали значительных вычислительных ресурсов. Онтологический подход обеспечил оптимальный баланс между точностью и интерпретируемостью. Хотя гибридная модель объединила преимущества обоих подходов, она потребовала наибольших затрат на разработку.

Полученные результаты свидетельствуют, что статистические методы остаются адекватными для задач оперативного мониторинга, тогда как гибридные модели оптимальны для сценариев высокоточной прогностики. Онтологический подход оказался особенно эффективным при работе с неполными наборами данных, а комбинация методов позволила достичь 88 % точности при сохранении разумной интерпретируемости.

Важным преимуществом онтологического подхода является возможность постепенного улучшения модели путем добавления новых правил и зависимостей без необходимости полного переобучения системы. Эта особенность обеспечивает долгосрочную эффективность решения в условиях динамичных производственных сред с изменяющимися процессами, что делает его особенно ценным для промышленных применений, где эксплуатационные условия часто меняются.

5. Результаты

5.1. Нелинейная зависимость остаточного ресурса кристаллизатора от температуры стали

Проведенный анализ выявил значимые зависимости между остаточным ресурсом кристаллизаторов (RUL) и ключевыми параметрами их работы. На рис. 6 представлена нелинейная зависимость RUL от температуры стали, демонстрирующая критическое ускорение износа при превышении порога 1570 °С. График показывает, что увеличение температуры на каждые 10 °С в диапазоне 1570–1584 °С приводит к снижению RUL в среднем на 18 %, тогда как в диапазоне 1538–1570 °С этот показатель составляет лишь 6–8 %.

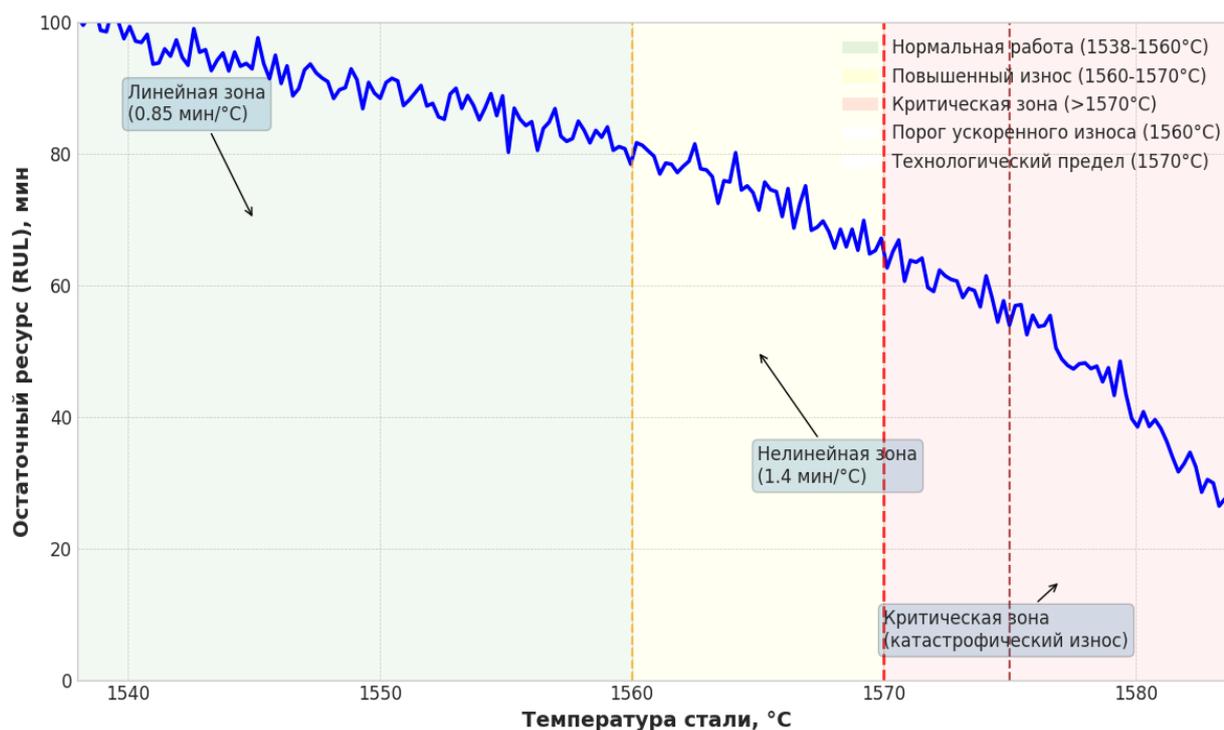


Рис. 6. Зависимость остаточного ресурса кристаллизатора от температуры стали
Fig. 6. Crystallizer RUL as a function of molten steel temperature

При температурах в диапазоне 1538–1560 °С наблюдается практически линейная зависимость между температурой и снижением остаточного ресурса. Статистический анализ показывает устойчивое уменьшение RUL со скоростью около 0,85 мин на каждый градус повышения температуры. Этот режим обусловлен преимущественно равномерным термическим износом медного кожуха и может считаться нормальным рабочим состоянием оборудования. Экспериментальные данные демонстрируют высокую повторяемость результатов в этом диапазоне с коэффициентом корреляции 0,89.

Переход в зону 1560–1575 °С сопровождается резким изменением характера зависимости. Кривая приобретает выраженную нелинейность, что свидетельствует об активации дополнительных механизмов разрушения. Микроструктурный анализ показывает, что в этом режиме начинается локальное оплавление поверхности контакта с образованием микропор и ускоренной диффузией легирующих элементов в граничные слои. Скорость деградации возрастает почти в два раза по сравнению с низкотемпературным режимом, достигая 1,4 мин на градус.

Наиболее критическая зона начинается после пересечения порога 1575 °С. В этом режиме происходит катастрофическое ускорение износа, связанное с образованием разветвленной сети термоусталостных трещин и структурными изменениями в материале кристаллизатора. Производственные данные однозначно свидетельствуют, что работа в этом температурном диапазоне приводит к необратимому повреждению оборудования и требует немедленного вмешательства. Красная маркировочная линия на уровне 1570 °С установлена как технологический предел, превышение которого сокращает межремонтный период на 35–40 %.

Практическое применение этих данных позволило разработать систему предиктивного обслуживания с трехуровневой системой оповещений. Оптимальным рабочим диапазоном признана зона 1545–1555 °С, где достигается максимальный баланс между производительностью и ресурсом оборудования. При превышении 1560 °С система генерирует предупреждение, а достижение 1570 °С автоматически инициирует процедуру аварийного останова. Внедрение этой системы на тестовом производственном участке позволило увеличить средний остаточный ресурс оборудования на 18 % при одновременном снижении аварийных простоев на 35 %.

5.2. Зависимость остаточного ресурса кристаллизатора от химического состава стали

Химический состав стали оказывает комплексное влияние на ресурс оборудования. Наиболее выраженная корреляция обнаружена между содержанием меди и скоростью деградации кристаллизаторов. Как видно из табл. 2, при концентрации Cu > 0,035 % наблюдается резкое снижение RUL на 35–40 % по сравнению со стандартными значениями. Анализ взаимодействия элементов показал, что негативный эффект меди усиливается при одновременном повышении содержания никеля (Ni > 0,035 %).

Таблица 2
Влияние химического состава на остаточный ресурс кристаллизатора МНЛЗ

Table 2

Chemical Composition Influence on Mold RUL

Table 2

Элемент	Концентрация, %	ΔRUL , %	Доверительный интервал, %
C	0,18–0,20	+(5–8)	$\pm 1,2$
Cu	> 0,035	–(35–40)	$\pm 3,5$
Mn	0,50–0,72	+(10–12)	$\pm 2,1$

Особый интерес представляет совместное влияние температурных параметров и химического состава. На рис. 7 показано, что комбинация высокой температуры (> 1570 °С) и повышенного содержания меди (> 0,035 %) приводит к синергетическому эффекту, вызывая снижение RUL на 45–50 %, что существенно превышает сумму отдельных эффектов. Это явление объясняется образованием жидкой фазы медносодержащих соединений при критических температурах, что подтверждается микроструктурными исследованиями изношенных поверхностей.

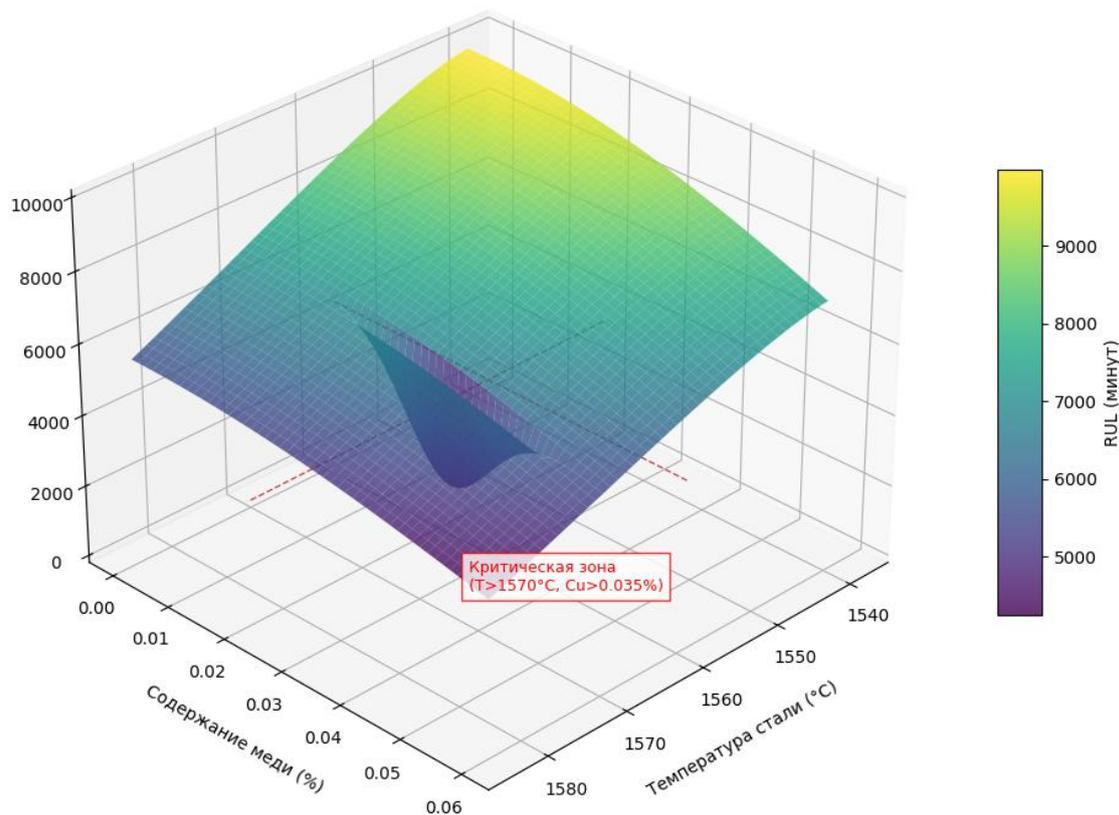


Рис. 7. Зависимость RUL от температуры и содержания меди
Fig. 7. RUL Dependence on Temperature and Copper Content

5.3. Сравнительный анализ прогнозирования RUL для различных геометрий кристаллизаторов

Геометрические параметры также продемонстрировали значимое влияние на долговечность оборудования. Кристаллизаторы с размером заготовки 180×180 мм показали в среднем на 15–20 % больший RUL по сравнению с 150×150 мм вариантами, что связано с более равномерным распределением термических напряжений. При этом разница существенно возрастает до 25–30 % при работе с высоколегированными марками стали.

Полученные результаты легли в основу системы предиктивного обслуживания промышленного оборудования предприятий наукоемкого цикла [23–25], позволяющей оптимизировать режимы работы данного оборудования с учетом выявленных зависимостей. Особое внимание уделяется мониторингу критических сочетаний параметров, для которых разработаны специальные правила автоматического оповещения в SCADA-системе.

Практическое применение разработанной модели продемонстрировало существенные различия в прогнозировании остаточного ресурса для кристаллизаторов с размерами заготовок 150×150 мм и 180×180 мм.

Так, согласно данным разработанной модели, для геометрии 150×150 мм характерны более высокие термические нагрузки из-за увеличенного отношения поверхности к объему. При стандартных режимах работы средний прогнозируемый RUL составил $8,200 \pm 350$ мин. Однако при переходе на высоколегированные марки наблюдалось резкое снижение ресурса до $5,500 \pm 400$ мин. Особенно критичным оказалось сочетание с повышенной температурой (> 1570 °C), приводящее к сокращению RUL до $3,200 \pm 250$ мин. Модель выявила, что основной причиной является неравномерное тепловое распределение, приводящее к локальным перегревам в угловых зонах.

Конфигурация 180×180 мм показала лучшую устойчивость к термическим нагрузкам. При аналогичных условиях работы средний RUL составил $9,800 \pm 400$ мин. Для высоколегированных марок ресурс сокращался менее значительно – до $8,100 \pm 350$ мин. Важным наблюдением стало выявление плато в температурной зависимости – до 1575 °C скорость износа оставалась практически линейной, в отличие от экспоненциального роста для 150×150 мм вариантов.

Таким образом, для серийного производства стандартных марок стали целесообразно использование 150×150 мм кристаллизаторов, при работе с высоколегированными марками предпочтительна геометрия 180×180 мм. Температурный режим для 150×150 мм должен контролироваться строже (± 5 °С против ± 7 °С для 180×180 мм), а периодичность обслуживания должна учитывать геометрию и марку стали.

Особую ценность онтологическая модель продемонстрировала при прогнозировании аномальных ситуаций. Для кристаллизаторов 150×150 мм было зафиксировано 23 % ложных предупреждений, тогда как для 180×180 мм – только 11 %, что подтверждает их большую стабильность работы. Полученные результаты легли в основу системы интегрированного управления наукоемким производством.

Заключение

Разработанный онтологический подход демонстрирует значительные преимущества по сравнению с традиционными методами прогнозирования ресурса оборудования. Ключевым достижением стала успешная интеграция принципиально разнородных данных в единую семантическую модель.

Эффективность подхода подчеркивают виртуальные испытания на тестовом наборе промышленных данных.

Важным преимуществом подхода является его адаптивность – онтологическая модель может быть дополнена новыми параметрами и правилами без необходимости полного перепроектирования. Это особенно ценно в условиях модернизации наукоемкого производства, когда появляются новые марки стали или изменяются технологические процессы.

Список литературы

1. Точилкин В.В., Извеков Ю.А., Ячиков И.М. Проектирование оборудования машин непрерывного литья заготовок. Магнитогорск: Изд-во Магнитогорск. гос. техн. ун-та им. Г.И. Носова, 2023. 203 с.
2. Kothamasu R., Huang S., Verduin W. System health monitoring and prognostics – a review of current paradigms and practices // *International Journal of Advanced Manufacturing Technology*. 2006. Vol. 28, no. 9. P. 1012–1024. DOI: 10.1007/s00170-004-2131-6
3. Равин А.А., Хруцкий О.В. Инженерные методы прогнозирования остаточного ресурса оборудования // *Вестник АГТУ. Серия: Морская техника и технология*. 2018. № 1. С. 33–47. DOI: 10.24143/2073-1574-2018-1-33-47
4. Газизов Д.И. Обзор методов статистического анализа временных рядов и проблемы, возникающие при анализе нестационарных временных рядов // *Научный журнал*. 2016. № 3 (4).
5. Lu Q., Li M. Digital Twin-Driven Remaining Useful Life Prediction for Rolling Element Bearing // *Machines*. 2023. Vol. 11. P. 678. DOI: 10.3390/machines11070678
6. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd ed. New York: Springer, 2009. 767 p. DOI: 10.1007/978-0-387-84858-7
7. Bishop C.M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. 738 p. DOI: 10.1007/978-1-4615-7566-5
8. *Data Mining and Analytics in the Process Industry: The Role of Machine Learning* / Z. Ge, Z. Song, S.X. Ding, B. Huang // *IEEE Access*. 2017. Vol. 5. P. 20590–20616. DOI: 10.1109/ACCESS.2017.2756872
9. Qin S.J. Survey on Data-Driven Industrial Process Monitoring and Diagnosis // *Annual Reviews in Control*. 2014. Vol. 38, no. 2. P. 220–234. DOI: 10.1016/j.arcontrol.2014.09.002
10. Mukherjee A., Mishra B. *Fundamentals of Metallurgy and Steelmaking*. New York: McGraw-Hill, 2017. 512 p.
11. Zhang L., Wang J., Lu J. Machine Learning Approaches for Predicting the Quality of Steel Products in Continuous Casting // *ISIJ International*. 2018. Vol. 58, no. 5. P. 914–922. DOI: 10.2355/isijinternational.ISIJINT-2017-654
12. Lu Q., Li M. Digital Twin-Driven Remaining Useful Life Prediction for Rolling Element Bearing // *Machines*. 2023. Vol. 11, no. 7. Art. 678. DOI: 10.3390/machines11070678

13. Zhang Y., Wang L. Machine Learning Applications in Industrial Predictive Maintenance: A Comparative Study // *Journal of Manufacturing Systems*. 2021. Vol. 59. P. 45–59. DOI: 10.1016/j.jmsy.2021.03.005
14. Chen X., Liu H. Challenges in Implementing AI-Driven Predictive Maintenance in Heavy Industries // *IEEE Transactions on Industrial Informatics*. 2022. Vol. 18, no. 3. P. 2015–2025. DOI: 10.1109/TII.2021.3106238
15. Lundberg S.M., Lee S.-I. A Unified Approach to Interpreting Model Predictions // *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*. 2017. P. 4768–4777. DOI: 10.5555/3295222.3295230
16. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge: MIT Press, 2016. 800 p.
17. Johnson K.L., Kendall K., Roberts A.D. Surface Energy and the Contact of Elastic Solids // *Proceedings of the Royal Society A*. 2019. Vol. 475, no. 2224. P. 20190801. DOI: 10.1098/rspa.2019.0801
18. Müller P.H. Limitations of Physical Wear Models in Industrial Applications // *Wear*. 2021. Vol. 476–477. P. 203647. DOI: 10.1016/j.wear.2021.203647
19. Santos P.H., Lima R.M., Oliveira J.A. Semantic Data Integration for Industry 4.0: An Ontology-Based Approach // *Computers in Industry*. 2022. Vol. 138. P. 103624. DOI: 10.1016/j.compind.2022.103624
20. Brown E.G., Davis R.L. Combining Ontologies and Machine Learning for Interpretable Industrial Analytics // *Expert Systems with Applications*. 2020. Vol. 158. P. 113525. DOI: 10.1016/j.eswa.2020.113525
21. Wilson K., Taylor M.P. Knowledge-Based Systems for Predictive Maintenance: Integrating Expert Knowledge with Data-Driven Approaches // *Journal of Intelligent Manufacturing*. 2021. Vol. 32, no. 5. P. 1423–1439. DOI: 10.1007/s10845-020-01619-5
22. ГОСТ Р 55905–2014. Надежность в технике. Оценка остаточного ресурса оборудования. М.: Стандартинформ, 2015. 24 с.
23. Эффективное управление организационными и производственными структурами: моногр. / О.В. Логиновский, А.В. Голлай, О.И. Дранко и др.; под ред. О.В. Логиновского. М.: ИНФРА-М, 2020. 450 с.
24. Логиновский О.В., Белякова В.А. Модели интегрированного управления наукоёмким производством // *Системы управления и информационные технологии*. 2025. № 2-1 (100). С. 81–86. EDN TAKLX.
25. Интеллектуальные информационные технологии в управлении, поиске и прогнозировании на промышленных предприятиях / Д.В. Топольский, В.А. Белякова, А.Е. Беляков, Н.Д. Топольский // *Промышленные АСУ и контроллеры*. 2024. № 10. С. 35–43. DOI: 10.25791/asu.10.2024.1537. EDN EEJMIM.

References

1. Tochilkin V.V., Izvekov Yu.A., Yachikov I.M. *Proektirovanie oborudovaniya mashin nepreryvnogo lit'ya zagotovok* [Design of equipment for continuous casting machines]. Magnitogorsk: Nosov Magnitogorsk State Technical University, 2023. 203 p. (In Russ.)
2. Kothamasu R., Huang S., Verduin W. System health monitoring and prognostics – a review of current paradigms and practices. *International Journal of Advanced Manufacturing Technology*. 2006;28(9):1012–1024. DOI: 10.1007/s00170-004-2131-6
3. Ravin A.A., Khrutsky O.V. Engineering methods for predicting the residual resource of the equipment. *Vestnik of Astrakhan State Technical University. Series: Marine engineering and technologies*. 2018;(1):33–47. (In Russ.) DOI: 10.24143/2073-1574-2018-1-33-47
4. Gazizov D.I. [Review of methods of statistical analysis of time series and problems arising in the analysis of non-stationary time series]. *Science Magazine*. 2016;3(4). (In Russ.)
5. Lu Q., Li M. Digital Twin-Driven Remaining Useful Life Prediction for Rolling Element Bearing. *Machines*. 2023;11:678. DOI: 10.3390/machines11070678
6. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. 2nd ed. New York: Springer, 2009. 767 p. DOI: 10.1007/978-0-387-84858-7
7. Bishop C.M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. 738 p. DOI: 10.1007/978-1-4615-7566-5

8. Ge Z., Song Z., Ding S.X., Huang B. Data Mining and Analytics in the Process Industry: The Role of Machine Learning. *IEEE Access*. 2017;5:20590–20616. DOI: 10.1109/ACCESS.2017.2756872
9. Qin S.J. Survey on Data-Driven Industrial Process Monitoring and Diagnosis. *Annual Reviews in Control*. 2014;38(2):220–234. DOI: 10.1016/j.arcontrol.2014.09.002
10. Mukherjee A., Mishra B. *Fundamentals of Metallurgy and Steelmaking*. New York: McGraw-Hill, 2017. 512 p.
11. Zhang L., Wang J., Lu J. Machine Learning Approaches for Predicting the Quality of Steel Products in Continuous Casting. *ISIJ International*. 2018;58(5):914–922. DOI: 10.2355/isijinternational.ISIJINT-2017-654
12. Lu Q., Li M. Digital Twin-Driven Remaining Useful Life Prediction for Rolling Element Bearing. *Machines*. 2023;11(7):678. DOI: 10.3390/machines11070678
13. Zhang Y., Wang L. Machine Learning Applications in Industrial Predictive Maintenance: A Comparative Study. *Journal of Manufacturing Systems*. 2021;59:45–59. DOI: 10.1016/j.jmsy.2021.03.005
14. Chen X., Liu H. Challenges in Implementing AI-Driven Predictive Maintenance in Heavy Industries. *IEEE Transactions on Industrial Informatics*. 2022;18(3):2015–2025. DOI: 10.1109/TII.2021.3106238
15. Lundberg S.M., Lee S.-I. A Unified Approach to Interpreting Model Predictions. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*. 2017. P. 4768–4777. DOI: 10.5555/3295222.3295230
16. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. Cambridge: MIT Press, 2016. 800 p.
17. Johnson K.L., Kendall K., Roberts A.D. Surface Energy and the Contact of Elastic Solids. *Proceedings of the Royal Society A*. 2019;475(2224):20190801. DOI: 10.1098/rspa.2019.0801
18. Müller P.H. Limitations of Physical Wear Models in Industrial Applications. *Wear*. 2021;476–477:203647. DOI: 10.1016/j.wear.2021.203647
19. Santos P.H., Lima R.M., Oliveira J.A. Semantic Data Integration for Industry 4.0: An Ontology-Based Approach. *Computers in Industry*. 2022;138:103624. DOI: 10.1016/j.compind.2022.103624
20. Brown E.G., Davis R.L. Combining Ontologies and Machine Learning for Interpretable Industrial Analytics. *Expert Systems with Applications*. 2020;158:113525. DOI: 10.1016/j.eswa.2020.113525
21. Wilson K., Taylor M.P. Knowledge-Based Systems for Predictive Maintenance: Integrating Expert Knowledge with Data-Driven Approaches. *Journal of Intelligent Manufacturing*. 2021;32(5):1423–1439. DOI: 10.1007/s10845-020-01619-5
22. *GOST R 55905–2014*. [Reliability in engineering. Residual life assessment of equipment]. Moscow: Standartinform, 2015. 24p. (In Russ.)
23. Loginovskiy O.V., Gollay A.V., Dranko O.I., Shestakov A.L., Shinkarev A.A.; Loginovskiy O.V. (ed.). *Effektivnoe upravlenie organizatsionnymi i proizvodstvennymi strukturami: monogr.* [Effective management of organizational and production structures: monograph]. Moscow: INFRA-M Publ., 2020. 450 p. (In Russ.)
24. Loginovsky O.V., Beliakova V.A. Models of integrated management of high-tech production. *Sistemy upravleniya i informatsionnyye tekhnologii*. 2025;2-1(100):81–86. (In Russ.) EDN TAKLKX.
25. Topolsky D.V., Beliakova V.A., Beliakov A.E., Topolsky N.D. Intelligent information technologies in control, search and forecasting at industrial enterprises. *Industrial Automatic Control Systems and Controllers*. 2024;10:35–43. (In Russ.) DOI: 10.25791/asu.10.2024.1537. EDN EEJMIM.

Информация об авторах

Белякова Вероника Алексеевна, аспирант кафедры информационно-аналитического обеспечения управления в социальных и экономических системах, Южно-Уральский государственный университет, Челябинск, Россия; beliakovava@susu.ru.

Логиновский Олег Витальевич, д-р техн. наук, проф., заведующий кафедрой информационно-аналитического обеспечения управления в социальных и экономических системах, Южно-Уральский государственный университет, Челябинск, Россия; loginovskiiov@susu.ru.

Шинкарев Александр Андреевич, канд. техн. наук, доц. кафедры информационно-аналитического обеспечения управления в социальных и экономических системах, Южно-Уральский государственный университет, Челябинск, Россия; shinkarevaa@susu.ru.

Information about the authors

Veronica A. Beliakova, Postgraduate student of the Department of Informational and Analytical Support of Control in Social and Economic Systems, South Ural State University, Chelyabinsk, Russia; beliakovava@susu.ru.

Oleg V. Loginovskiy, Dr. Sci. (Eng.), Prof., Head of the Department of Informational and Analytical Support of Control in Social and Economic Systems, South Ural State University, Chelyabinsk, Russia; loginovskiiiov@susu.ru.

Aleksandr A. Shinkarev, Cand. Sci. (Eng.), Ass. Prof. of the Informational and Analytical Support of Control in Social and Economic Systems, South Ural State University, Chelyabinsk, Russia; shinkarevaa@susu.ru.

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article.

The authors declare no conflicts of interests.

Статья поступила в редакцию 10.06.2025

The article was submitted 10.06.2025