

УДК 004.89
DOI 10.52575/2687-0932-2025-52-3-681-696
EDN VHBEII

Поддержка принятия решений о качестве работы оборудования на машиностроительном предприятии на основе интеллектуальных методов

Конев К.А.

Уфимский университет науки и технологий,
Россия, 450076, Республика Башкортостан, г. Уфа, ул. Заки Валиди, д. 32
sireo@rambler.ru

Аннотация. Статья посвящена описанию подходов к реализации системы поддержки принятия решений на основе ситуационно-онтологического моделирования и методов машинного обучения для оценки состояния металлорежущего оборудования на машиностроительном предприятии. Исследование проводилось с целью повышения точности прогнозирования состояния станков и обоснованности решений о их обслуживании или ремонте, что особенно важно в условиях авиационного машиностроения с высокими требованиями к качеству продукции. Актуальность исследования обусловлена необходимостью минимизации брака, снижения простоев и повышения эффективности управления парком оборудования, включающим станки различного возраста и технического состояния. Новизна предложенного решения заключается в интеграции онтологической модели, формализующей знания о ситуациях, решениях и сценариях, с моделью градиентного бустинга, предназначенной для прогнозирования необходимости ремонта на основе исторических данных. Практическая ценность выражается в возможности автоматизации анализа состояния оборудования, интерпретируемости результатов прогнозирования и внедрении системы в реальные производственные процессы для повышения надежности и качества выпускаемых деталей. Результаты исследования демонстрируют работоспособность предложенного подхода и его применимость для решения задач обеспечения качества в машиностроении.

Ключевые слова: машинное обучение, принятие решений, ситуационно-онтологическая методология разработки систем поддержки принятия решений, OWL-модель, обеспечение качества, Python, металлорежущее оборудование, градиентный бустинг

Для цитирования: Конев К.А. 2025. Поддержка принятия решений о качестве работы оборудования на машиностроительном предприятии на основе интеллектуальных методов. *Экономика. Информатика*, 52(3): 681–696. DOI 10.52575/2687-0932-2025-52-3-681-696. EDN VHBEII

Support for Decision-Making on the Quality of Equipment Operation at a Mechanical Engineering Enterprise Based on Intelligent Methods

Konstantin A. Konev

Ufa University of Science and Technology,
32 Zaki Validi St., Ufa 450076, Republic of Bashkortostan, Russia
sireo@rambler.ru

Abstract. The article describes approaches to implementing a decision support system based on situational-ontological modeling and machine learning methods for assessing the state of metal-cutting equipment at a mechanical engineering enterprise. The study was conducted to improve the accuracy of forecasting the state of machines and the validity of decisions on their maintenance or repair, which is especially important in the context

© Конев К.А., 2025



of aircraft engineering with high requirements for product quality. The relevance of the study is due to the need to minimize defects, reduce downtime and improve the efficiency of managing a fleet of equipment, including machines of different ages and technical conditions. The novelty of the proposed solution lies in the integration of an ontological model that formalizes knowledge about situations, decisions and scenarios, with a gradient boosting model designed to predict the need for repairs based on historical data. The practical value is expressed in the ability to automate the analysis of the equipment state, interpretability of the forecasting results and the implementation of the system in real production processes to improve the reliability and quality of manufactured parts. The results of the study demonstrate the operability of the proposed approach and its applicability to solving quality assurance problems in mechanical engineering.

Keywords: machine learning, decision making, situational-ontological methodology for developing decision support systems, OWL model, quality assurance, Python, metal-cutting equipment, gradient boosting

For citation: Konev K.A. 2025. Support for Decision-Making on the Quality of Equipment Operation at a Mechanical Engineering Enterprise Based on Intelligent Methods. *Economics. Information technologies*, 52(3): 681–696 (in Russian). DOI 10.52575/2687-0932-2025-52-3-681-696. EDN VHBEII

Введение

Качество продукции в авиационном машиностроении напрямую зависит от точности и надежности металлорежущего оборудования [Еленев, 2023]. Особую значимость этот аспект приобретает в механосборочных цехах, где серийное производство деталей сопровождается высокими требованиями к точности и минимизации брака. При этом даже незначительные отклонения в работе одного станка могут спровоцировать серьезные нарушения технологических процессов и привести к значительным экономическим потерям.

Актуальной задачей становится не просто контроль состояния оборудования, но и упреждающий анализ его работы. Именно здесь на первый план выходят методы машинного обучения [Machine Learning, 2025], которые позволяют не только выявлять проблемные зоны, но и прогнозировать их развитие. Такой подход создает прочную основу для принятия обоснованных решений о необходимости обслуживания или замены оборудования, что существенно повышает эффективность управления производственными процессами.

Ситуационно-онтологический подход к принятию решений по вопросам оборудования

Ситуационно-онтологический подход представляет собой методологию, объединяющую ситуационное моделирование и онтологическое представление знаний для поддержки принятия решений в сложных производственных системах [Конеv, 2024]. Его основу составляет теоретико-множественное описание взаимосвязей между уровнями управления (продукт, процесс, система), а знания о предметной области формализуются через концепты, отношения и правила. Такая структура позволяет эффективно организовать данные о бизнес-процессах, ситуациях, решениях и сценариях их реализации, особенно при работе с большими объемами информации и в условиях неопределенности.

В механосборочном производстве [Воронин, 1985] контроль состояния оборудования усложняется ограниченными ресурсами предприятия [Янов, 2024]. Количество специалистов недостаточно для постоянного мониторинга всего станочного парка, что создает риски возникновения нештатных ситуаций. Неисправности или неправильная настройка оборудования могут привести к серьезным последствиям: росту процента брака, остановке производственной линии и значительным экономическим потерям. Внезапные отказы случаются редко, поскольку обычно им предшествуют деградиационные процессы, которые можно выявить на ранних этапах [Шашок, 2001].

Для решения этой задачи предлагается применить ситуационно-онтологический подход, который формализует знания о работе оборудования, автоматизирует анализ данных и генерирует рекомендации для принятия решений [Антонов, 2021]. На первом этапе

проводится идентификация ситуации с использованием лингвистических переменных и семантических мер, что позволяет учитывать как количественные, так и качественные характеристики проблемы.

Формально ситуация S может быть определена как подмножество онтологии O предметной области $O = \langle C, R, F \rangle$, где C – множество концептов (например, «станок», «ремонт», «брак»), R – множество отношений между концептами, F – множество функций интерпретации [Гаврилова, 2000]. В этом случае $S \subseteq O$, т. е. ситуация является элементом онтологии.

Идентификация ситуации может быть выражена через функцию выбора f_{sel} , которая на основе множества параметров оборудования $Ch = \{ch_1, \dots, ch_n\}$ и множества правил $Cr = \{cr_1, \dots, cr_m\}$ возвращает конкретную ситуацию s_i : $s_i = f_{sel}(Ch, Cr)$.

Каждая ситуация характеризуется набором весовых коэффициентов w_j , соответствующих важности параметра ch_j , а также значениями самих параметров x_{ij} , определёнными для станка i . Тогда взвешенная сумма показателей для ситуации может быть представлена как:

$$W_i = \sum_{j=1}^n w_j x_{ij}. \quad (1)$$

Особое значение при анализе состояния оборудования имеет метод Парето, позволяющий выделить 20 % наиболее проблемного оборудования, ответственного за 80 % всех производственных отклонений. В рамках СОП метод Парето мы применим на этапе идентификации ситуации для ранжирования оборудования по степени риска.

Пусть $Eq = \{eq_1, \dots, eq_k\}$ – множество единиц оборудования, а $W(eq_i)$ – взвешенная сумма характеристик станка eq_i , определённая по (1). Тогда оборудование ранжируется по убыванию $W(eq_i)$, и выбираются те станки, которые составляют 20 % от общего числа, но дают не менее 80 % совокупного значения W .

Формула для определения порога отбора по методу Парето [Тихвинский, 2022] может быть представлена следующим образом:

$$Eq_{NA} = \left\{ eq_i \in Eq \mid \frac{\sum_{eq_i \in Eq_{i20}} W(eq_i)}{\sum_{eq_i \in Eq} W(eq_i)} \geq 0.8 \right\}, \quad (2)$$

где Eq_{NA} – множество станков, находящихся в состоянии, которое требует детального анализа; Eq_{i20} – лучшие 20 % оборудования по значению $W(eq_i)$.

На основании выражения (2) можно определять перечень станков, которые требуют более детального анализа.

Затем строится классификация возможных решений, учитывающая специфику ситуаций. Особое внимание уделяется интеграции нормативных требований и эмпирических знаний специалистов через формализованные правила «ЕСЛИ-ТО», которые становятся основой для автоматизированных механизмов принятия решений. Интеграция нормативных документов через OWL-модели [Самигулина, 2015] создает единое информационное пространство для принятия решений на всех уровнях управления. Система поддержки принятия решений (СППР), основанная на этом подходе, способна анализировать замеры, данные с датчиков, оценивать риски и генерировать конкретные рекомендации для исполнителей, что повышает эффективность работы механосборочных цехов за счет снижения времени на анализ проблем, минимизации ошибок и автоматизации документооборота.



Описание ситуации на предприятии

Ключевой задачей машиностроительного предприятия является обеспечение точности изготовления деталей, так как значительная часть продукции относится к категории особо ответственных [Казюлин, 2024]. Для анализа текущего состояния оборудования и выявления рисков, связанных с износом узлов и механизмов старых станков, необходимо знать основные характеристики и состояние этого оборудования (табл. 1).

Таблица 1
Table 1

Основные характеристики станков цеха
Main characteristics of the workshop machines

Тип станка	Модель	Год вып.	Посл. ремонт	Основные виды операций	Статус	Примечание (риски)
Токарный	1М63НФ3	1985	кв. 4 2020	Токарная обработка, расточка	Работает	Износ направляющих, риск поломки шпинделя
Токарный	DMG Mori NLX 3000	2021	Нет	Многофункциональная обработка	Работает	—
Токарный	16Б16	1992	кв. 2 2022	Черновая токарная обработка	Работает	Износ направляющих, требуется регулярная смазка
Фрезерный	6P13	1982	кв. 3 2018	Фрезерование плоскостей	В ремонте	Капитальный ремонт
Фрезерный	Haas VF-2	2015	кв. 1 2023	3D-фрезерование	Работает	Необходима профилактика системы охлаждения
Сверлильный	2A135	1992	кв. 2 2021	Сверление, зенкерование	Работает	Износ шпинделя, возможны отклонения в точности
Шлифовальный	3A151	1995	кв. 4 2021	Плоское шлифование	Работает	Возможны отклонения в размерах
Ленточно-пильный	Kasto Microcut 5.6	2021	Нет	Точная резка заготовок	Работает	—
Электро-эрозионный	APT-250	1991	кв. 3 2021	Электроэрозионная обработка	Работает	Необходима замена электродов
Координатно-расточной	2A458	1985	кв. 4 2020	Расточка прецизионных отверстий	В резерве	Устаревшая модель, низкая точность
Координатно-расточной	Moore Jig Grinders	2020	Нет	Высокоточная расточка	Работает	—

Анализ данных выделяет три основные группы оборудования: изношенные станки старого парка (например, токарный 1М63НФ3), современные высокотехнологичные станки (DMG Mori NLX 3000, Moore Jig Grinders) и оборудование среднего возраста (Haas VF-2, 2A135), требующее регулярного обслуживания. Для систематизации оценки состояния и принятия решений об обслуживании была разработана модель, структурирующая информацию о ситуациях, решениях и сценариях, которая формализует знания о работе

оборудования через классификацию параметров и их взаимодействий. Такая структуризация особенно важна для старого и смешанного парков оборудования разного возраста и состояния, создавая основу для автоматизированного анализа данных и генерации рекомендаций по обслуживанию [Матвеева, 2021]. Рассмотрим описание онтологии о состоянии оборудования и возможных действиях при проблемных ситуациях.

Полное описание онтологии

Для описания онтологии необходимо задать методы, которые будут использоваться на этапах от идентификации ситуации до реализации принятого решения. В этом случае классы, их подклассы и свойства онтологии будут иметь вид:

1. Класс «Ситуация» представляет собой описание текущего состояния оборудования, включая его параметры, тренды и другие характеристики, которые могут указывать на потенциальные проблемы.

Подкласс «Ситуация_Парето» описывает ситуацию, где анализируется оборудование с использованием метода Парето для выявления 20 % станков, ответственных за 80 % проблем.

Характеристики:

- возраст (количество лет с момента выпуска станка);
- количество ремонтов (число проведенных ремонтов);
- время простоя (длительность простоев за период);
- общий ресурс (накопленный ресурс работы);
- замены узлов (число замен ключевых узлов);
- стоимость переделки (затраты на исправление брака);
- критичность деталей (важность изготавливаемых деталей);
- значимость в цепочке (роль оборудования в технологической цепочке);
- тренд брака (направление изменения процента брака: нет, слабый, явный);
- функциональные тренды (наличие негативных изменений по точности обработки).

Правила:

– ЕСЛИ возраст > 3 И количество ремонтов > 3 И время простоя > 50 %, ТО ситуация классифицируется как критическая, и оборудование включается в детальный анализ.

– ЕСЛИ тренд брака = «явный» И функциональные тренды = «слабые или явные» И критичность деталей ≥ 4 , ТО оборудование не включается в детальный анализ.

2. Класс: «Решение» представляет собой действия или рекомендации, предлагаемые системой для устранения выявленной ситуации.

Подкласс «Решение_ГрадиентныйБустинг» описывает решения, основанные на прогнозах модели градиентного бустинга.

Характеристики: прямолинейность (мм/м), круглость (мм), радиальное биение ($^{\circ}$), концентричность (мм), параллельность (мм/м), процент брака (%), кол-во ремонтов, время простоя (часы), стоимость переделки (руб.), критичность деталей (шкала 1–5), значимость в цепочке (шкала 1–5), вероятность отказа (вероятность необходимости ремонта), важность признаков (факторы, влияющие на прогноз).

Правила:

– ЕСЛИ процент брака > 0.7 И прямолинейность > 0.08 мм/м И радиальное биение > 0.03° , ТО решение = «Требуется немедленный ремонт».

– ЕСЛИ вероятность отказа > 0.8 И круглость > 0.1 мм И концентричность > 0.04 мм И параллельность > 0.06 мм/м, ТО решение = «Провести регулировку станка».

– ЕСЛИ важность признака «процент брака» > 0.4 И время простоя > 20 часов, ТО решение = «Проверить точность обработки».

3. Класс «Сценарий» Представляет собой последовательность действий или шагов, которые необходимо выполнить для реализации выбранного решения. В данной задаче он не рассматривается.

4. Класс «Характеристика» Представляет собой параметры, используемые для описания ситуации, решения или сценария.

Подклассы:

- «Характеристика_Оборудования» описывает физические и функциональные параметры оборудования (например, возраст, количество ремонтов).
- «Характеристика_Процесса» описывает параметры производственного процесса (например, процент брака, время простоя).

5. Класс «Правило» представляет собой логические условия, используемые для классификации ситуаций, принятия решений или формирования сценариев.

Подклассы:

- «Правило_Парето» описывает правила, основанные на методе Парето (например, отбор оборудования по сумме взвешенных показателей).
- «Правило_ГрадиентныйБустинг» описывает правила, основанные на прогнозах модели градиентного бустинга (например, вероятность отказа).
- «Правило_ЖесткиеПравила» описывает жесткие правила «ЕСЛИ-ТО» для реализации сценариев.

Обобщённая OWL-модель для данной ситуации показана на рис. 1.




Рис. 1. OWL-модель процесса принятия решений по выявлению проблемных станков
Fig. 1. OWL model of decision making process for identifying problematic machines

6. Свойства:

- «имеетХарактеристику» связывает классы «Ситуация», «Решение» и «Сценарий» с классом «Характеристика»;
- «определяетсяПравилом» связывает классы «Ситуация», «Решение» и «Сценарий» с классом «Правило»;
- «связаноСМетодом» ассоциирует классы «Ситуация» и «Решение» с методами анализа;
- «реализуетсяЧерезСценарий» создаёт связь между классом «Решение» и классом «Сценарий».

На основе представленной OWL-модели процесса принятия решений (рис. 1) можно перейти к практическому анализу оборудования на уровне ситуации, используя метод Парето. Данная модель позволит формализовать взаимосвязь между ключевыми элементами системы: ситуациями, решениями и сценариями их реализации.

Рассмотрим практическое применение этого подхода для анализа состояния описанного выше станочного парка.

Анализ оборудования на уровне ситуации

Точность металлорежущего оборудования является значимым фактором снижения производственных рисков [Пономарев, 2021]. Своевременное выявление отклонений в работе станков уменьшает затраты на устранение брака и повышает качество продукции. Для достижения этой цели предлагаются следующие этапы проверки:

- первичный контроль основных параметров с использованием современных измерительных инструментов;
- регистрация данных в автоматизированной системе мониторинга;
- анализ трендов изменения параметров за определенный период.

Необходимо отметить, что внедрение цифровых технологий для сбора и обработки данных играет ключевую роль в повышении качества проверки [Кабалдин, 2018]. Такой подход позволяет минимизировать влияние человеческого фактора, сократить время на выполнение замеров и исключить ошибки, связанные с ручным вводом информации. Автоматизация процесса сбора данных также создает основу для более глубокого анализа состояния оборудования.

Рассмотрим две таблицы замеров, демонстрирующие состояние нового токарного станка (DMG Mori NLX 3000, 2021 год выпуска) и старого токарного станка (16Б16, 1992 год выпуска). Из табл. 2 видно, что все параметры [Малкина, 2022] нового станка находятся в пределах допустимых норм, а тренды изменения характеристик полностью отсутствуют, что свидетельствует о высокой надежности оборудования и его способности поддерживать стабильное качество обработки деталей на протяжении длительного времени.

Таблица 2

Table 2

Таблица замеров для нового токарного станка (DMG Mori NLX 3000, 2021 год выпуска)
Measurement table for a new lathe (DMG Mori NLX 3000, 2021)

Параметр	Янв	Фев	Мар	Апр	Май	Июн	Июл	Авг	Сен	Окт	Ноя	Дек	Тренд
Прямолинейность (мм/м)	0,01	0,01	0,00	0,00	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,00	Нет
Круглость (мм)	0,02	0,01	0,02	0,01	0,01	0,02	0,01	0,00	0,01	0,02	0,01	0,02	Нет
Радиальное биение (°)	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,00	0,01	0,01	0,01	0,01	Нет
Концентричность (мм)	0,00	0,01	0,02	0,01	0,01	0,00	0,01	0,01	0,01	0,00	0,02	0,01	Нет
Параллельность (мм/м)	0,01	0,01	0,01	0,02	0,01	0,01	0,01	0,01	0,02	0,01	0,01	0,01	Нет
Процент брака (%)	0,00	0,00	0,00	0,00	0,00	0,04	0,00	0,00	0,00	0,00	0,00	0,02	Нет

Табл. 3, напротив, требует более детального анализа. Несмотря на то, что большинство параметров остаются в пределах допустимых значений, наблюдаются слабые тренды деградации по прямолинейности, круглости и проценту брака. Такая динамика указывает на необходимость дополнительного исследования состояния оборудования для выявления потенциальных рисков.

Рассмотрим шаги для определения перечня оборудования, требующего детального анализа на основе принципа Парето [Денисенко, 2023]. Согласно ему, наиболее значимые проблемы сосредоточены в 20 % оборудования, требующего особого внимания.

Таблица 3
Table 3

Таблица замеров для старого токарного станка (16Б16, 1992 год выпуска)
Measurement table for an old lathe (16B16, manufactured in 1992)

Параметр	Янв	Фев	Мар	Апр	Май	Июн	Июл	Авг	Сен	Окт	Ноя	Дек	Тренд
Прямолинейность (мм/м)	0,06	0,05	0,07	0,06	0,07	0,07	0,08	0,07	0,08	0,09	0,08	0,09	Слабый
Круглость (мм)	0,08	0,07	0,08	0,09	0,08	0,09	0,09	0,10	0,11	0,10	0,12	0,11	Слабый
Радиальное биение (°)	0,03	0,02	0,03	0,03	0,03	0,02	0,03	0,03	0,03	0,03	0,03	0,03	Нет
Концентричность (мм)	0,04	0,03	0,04	0,05	0,04	0,03	0,04	0,04	0,04	0,03	0,04	0,04	Нет
Параллельность (мм/м)	0,06	0,05	0,06	0,07	0,06	0,06	0,05	0,06	0,06	0,05	0,06	0,06	Нет
Процент брака (%)	0,54	0,55	0,53	0,61	0,64	0,65	0,73	0,62	0,69	0,81	0,78	0,79	Слабый

Соберём данные о состоянии оборудования, включая ключевые параметры (возраст, количество ремонтов, время простоя, тренды брака). Используем значимые параметры (возраст, количество ремонтов, время простоя и т. д.), описанные в предыдущей части статьи. Для определения суммарных показателей используем метод многокритериального выбора [Стойчич, 2019]. Каждому параметру присваивается весовой коэффициент (1–5) в зависимости от его значимости. Далее для каждой единицы оборудования рассчитывается взвешенный показатель (произведение значений параметров на их веса) и выполняется ранжирование по убыванию суммы (см. табл. 4).

Таблица 4
Table 4

Таблица для анализа станков по методу Парето
Table for machine analysis using the Pareto method

Показатель	Вес	1М63НФ3 (Токарный)	16Б16 (Токарный)	6Р13 (Фрезерный)	Haas VF-2 (Фрезерный)	2A135 (Сверильный)	APT-250 (Электроэроз.)	DMG Mori NLX 3000	Mazak VCN 510C	Kasto Microcut 5.6	Moore Jig Grinders
1	2	3	4	5	6	7	8	9	10	11	12
Возраст	3	3	2	3	2	2	2	1	1	1	1
Кол-во ремонтов	2	2	1	3	1	2	1	1	1	1	1
Время простоя	2	2	1	3	1	2	1	1	1	1	1
Общий ресурс	3	3	3	1	2	1	2	1	1	1	1
Замены узлов	3	2	3	2	1	2	1	2	1	1	0

Окончание табл. 4
End of the table 4

1	2	3	4	5	6	7	8	9	10	11	12
Стоимость переделки	4	3	2	1	2	3	2	1	0	0	0
Критичность деталей	5	2	3	2	2	2	2	0	0	0	0
Значимость в цепочке	4	3	3	2	2	2	3	1	1	1	1
Тренд брака	5	2	2	2	2	2	0	0	0	0	0
Функциональные тренды	5	2	0	4	2	0	2	0	0	0	0
Σ	-	69	63	61	55	49	49	17	10	10	7

По данным в таблице строится кумулятивная кривая диаграммы Парето, а на основании луча из точки её перегиба на ось абсцисс выделяется ~20 % станков, дающих ~80 % проблем, с проверкой значимости разрывов между ними (рис. 2).




Рис. 2. Диаграмма Парето для выбора станков для углублённого анализа
Fig. 2. Pareto diagram for selecting machines for in-depth analysis

Окончательный список формируется из наиболее критичных единиц с кратким обоснованием отбора (например, высокий износ или влияние на технологический процесс). В нашем случае на основе кумулятивной кривой Парето отобраны 6 станков с наибольшими суммами взвешенных показателей:

- токарный 1M63HФ3, являющийся старым станком с высоким износом и наличием тренда деградации;
- токарный 16B16, также относящийся к категории старых станков с высоким износом направляющих;
- фрезерный 6P13 – устаревшая модель с некоторыми проблемами;
- фрезерный Haas VF-2, который хотя и является новым станком с умеренными показателями, но тем не менее требует наблюдения по причине наличия слабого тренда деградации;
- сверлильный 2A135 – долго использовавшийся станок с признаками износа и слабым трендом брака;
- электроэрозионный APT-250 – станок со средним уровнем рисков, требующий дополнительного анализа.



Отобранные станки являются приоритетными для дальнейшего анализа, так как их состояние и тренды указывают на потенциальные риски, которые могут привести к увеличению брака или простоев. Рассмотрим на уровне решения детальный анализ по одной из единиц оборудования, состояние которой в результате оказалось хуже всех.

Детальный анализ состояния станка с использованием метода машинного обучения на основе исторических данных за 5 лет

Процедура анализа на основе исторических данных была проведена для всех 6 выбранных единиц оборудования, но наиболее тяжёлое состояние было выявлено по токарному станку 1М63НФЗ. Фрагмент таблицы исторических данных по станку 1М63НФЗ показан в табл. 5.

Таблица 5

Table 5

Фрагмент исторических данных за 2016–2020 гг. для станка 1М63НФЗ
 Fragment of historical data for 2016–2020 for the 1М63НФЗ machine

Год	Месяц	Прямолинейность (мм/м)	Круглость (мм)	Радиальное биение (°)	Концентричность (мм)	Параллельность (мм/м)	Процент брака (%)	Кол-во ремонтов	Время простоя (часы)	Оценка стоимости переделки (руб.)	Критичность деталей (1–5)	Значимость в цепочке (1–5)
2016	Янв	0,05	0,07	0,02	0,03	0,05	0,40	1	10	5000	3	4
2016	Фев	0,06	0,08	0,02	0,04	0,06	0,45	1	12	5500	3	4
2016	Мар	0,07	0,09	0,03	0,04	0,06	0,50	1	15	6000	3	4
...	...	...	...	...	...	...	...	...	...	...	...	...
2020	Ноя	0,08	0,11	0,03	0,04	0,06	0,78	2	20	8000	4	4
2020	Дек	0,09	0,12	0,03	0,04	0,06	0,80	2	22	8500	4	4

Таблица содержит исторические данные о работе станка 1М63НФЗ за период с 2016 по 2020 год. Для каждого месяца указаны значения функциональных параметров (например, прямолинейность, круглость, процент брака) и структурных/системных характеристик (например, количество ремонтов, время простоя, стоимость переделки).

Используем исторические данные для обучения модели градиентного бустинга [Ильичев, 2021] с целью прогнозирования состояния оборудования и выявления трендов деградации, поскольку данный метод (XGBoost, LightGBM, CatBoost) эффективно обрабатывает табличные данные, захватывает нелинейные зависимости, обеспечивает интерпретируемость и устойчивость к дисбалансу.

Отметим, что применение методов машинного обучения для анализа состояния оборудования позволяет не только прогнозировать его отказы, но и формировать обоснованные рекомендации по обслуживанию или ремонту без дополнительных проверок и вывода оборудования из эксплуатации [Конев, 2022]. Важно подчеркнуть, что использование градиентного бустинга над деревьями решений предоставляет возможность эффективно учитывать как функциональные параметры станков, так и их структурные и системные характеристики.

Алгоритм выбора оборудования для ремонта с использованием градиентного бустинга

Применение метода градиентного бустинга следует начать с подготовки исторических данных о состоянии оборудования за последние 5 лет. Данные должны включать как

функциональные параметры (например, прямолинейность, круглость, процент брака), так и структурные характеристики (возраст, количество ремонтов) и системные параметры (критичность деталей, значимость в цепочке).

На основе анализа данных определяется целевая переменная, например, метка «требуется ремонт», которая устанавливается по пороговым значениям ключевых параметров, таких как тренды деградации. Для повышения качества модели данные предварительно обрабатываются: удаляются пропуски, нормализуются числовые признаки и кодируются категориальные переменные.

Центральный этап – обучение модели градиентного бустинга, эффективного для работы с табличными данными, включая смешанные типы признаков. После обучения модель оценивается на тестовой выборке с использованием метрик точности, полноты и F1-меры. Высокие значения этих метрик подтверждают надёжность прогнозов.

Для интерпретации результатов анализируется важность признаков, что позволяет выявить ключевые факторы, влияющие на необходимость ремонта. На основе прогноза делаются выводы о состоянии оборудования и указываются причины, основанные на значимых параметрах.

Для наглядности строятся графики изменения параметров во времени и визуализируется важность признаков (см. рис. 3).




Рис. 3. Алгоритм выбора оборудования для ремонта с использованием градиентного бустинга
Fig. 3. Algorithm for selecting equipment for repair using gradient boosting

Предложенный алгоритм позволяет системно подходить к анализу состояния оборудования и выявлять признаки деградации на ранних этапах, что создает основу для принятия своевременных и обоснованных решений, направленных на минимизацию рисков и повышение эффективности производства.

Рассмотрим ключевые моменты алгоритма на языке Python [Коэльо, 2023].

Программа начинает свою работу с загрузки исторических данных о работе станка из CSV-файла, используя библиотеку `pandas` [McKinney, 2017]. Фрагмент кода и результат работы показаны на рис. 4.

На основе анализа с использованием градиентного бустинга можно сделать вывод, что станок 1М63НФ3 требует ремонта, что подтверждается высоким процентом брака и ухудшением функциональных параметров (см. рис. 5).

```
9 # Загрузка данных
10 data = pd.read_csv("historical_data_1M63NF3.csv")
11
12 # Целевая переменная: требуется ли ремонт
13 data['Requires_Repair'] = (data['Процент брака (%)'] > 0.7).astype(int)
14
15 # Удаление ненужных столбцов
16 data.drop(columns=['Год', 'Месяц'], inplace=True, errors='ignore')
17
18 # Разделение на признаки и целевую переменную
19 X = data.drop(columns=['Requires_Repair', 'Дата'])
20 y = data['Requires_Repair']
21
22 # Разделение на обучающую и тестовую выборки
23 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42, stratify=y)
24
25 # Обучение модели
26 model = CatBoostClassifier(
27     iterations=500,
28     learning_rate=0.1,
29     depth=6,
30     verbose=100,
31     random_state=42,
32     eval_metric='F1'
33 )
34 model.fit(X_train, y_train)
```

Отчет классификации:

	precision	recall	f1-score	support
0	1.00	1.00	1.00	8
1	1.00	1.00	1.00	4
accuracy			1.00	12
macro avg	1.00	1.00	1.00	12
weighted avg	1.00	1.00	1.00	12

Результат прогноза:
▲ Станок требует ремонта.
Вероятность необходимости ремонта: 99.90%

Рис. 4. Фрагмент кода и результат работы программы, реализующей метод градиентного бустинга на языке Python

Fig. 4. A code fragment and the result of the program implementing the gradient boosting method in Python

Поскольку процедура ремонта токарного оборудования на предприятии определена, то выбор сценария реализации не требуется, он реализуется по жёстким правилам, заданным нормативными документами.

Таким образом, ситуационно-онтологический подход, реализованный в виде системы поддержки принятия решений о состоянии металлорежущего оборудования, реализован и позволяет решать прикладные задачи в промышленности.




Рис. 5. Изменение параметров станка 1М63НФЗ во времени
Fig. 5. Change in the parameters of the 1M63NF3 machine over time

Важность признаков указывает на ключевые факторы, влияющие на прогноз, что позволяет целенаправленно планировать мероприятия по обслуживанию оборудования (см. рис. 6).




Рис. 6. Влияние измеримых и расчётных параметров станка 1М63НФЗ на результат
Fig. 6. The influence of measurable and calculated parameters of the 1M63NF3 machine on the result

Закключение

В статье представлен подход к двухуровневой поддержке принятия решений о состоянии металлорежущего оборудования на основе ситуационно-онтологического моделирования и методов машинного обучения. Предложенная онтология формализует знания о ситуациях, решениях и сценариях, обеспечивая единую основу для систематизации данных и автоматизации анализа. Метод Парето позволяет выделять 20 % оборудования, ответственного за 80% проблем, что повышает эффективность использования ограниченных ресурсов предприятия. На втором уровне применяется модель градиентного бустинга, обученная на исторических данных, которая прогнозирует необходимость ремонта станков с



высокой точностью. Интерпретируемость результатов через анализ важности признаков делает модель полезной для практиков. Практическая ценность заключается в возможности внедрения системы в реальные производственные процессы механосборочных цехов для снижения уровня брака, минимизации простоев и повышения обоснованности управленческих решений. Результаты исследования демонстрируют работоспособность предложенного подхода и его потенциал для цифровой трансформации процессов технического обслуживания и управления качеством на машиностроительных предприятиях.

Дальнейшие исследования будут посвящены расширению использования интеллектуальных методов в различных отраслях промышленности.

Список источников

Machine Learning in Manufacturing: Industrial Use Cases in 2025 [Электронный ресурс] MobiDev. 2025. Режим доступа: <https://mobidev.biz/blog/machine-learning-application-use-cases-manufacturing-industry> (дата обращения: 13.04.2025).

Список литературы

- Антонов В.В., Конев К.А., Куликов Г.Г. 2021. Трансформация модели системы поддержки принятия решений для типовых ситуаций с применением интеллектуальных и аналитических методов. *Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника»*. 21(3): 14–25. DOI 10.14529/ctcr210302
- Воронин А.В., Гречухин А.И., Калашников А.С. и др. 1985. Механизация и автоматизация сборки в машиностроении. М.: Машиностроение, 272.
- Гаврилова Т.А., Хорошевский В.Ф. 2000. Базы знаний интеллектуальных систем. СПб.: Питер, 384.
- Денисенко С.А., Булыгин Ф.В., Паньков А.Н. и др. 2023. Методологические основы принципа Парето и его реализация в физике и метрологии. *Компетентность*. 8: 15–23. DOI 10.24412/1993-8780-2023-8-15-23. EDN YGQTUE
- Еленев К.С., Малкова Т.Б., Еленева Ю.Я., Кудряшов С.А. 2023. Подходы к кластеризации металлорежущего и кузнечно-прессового оборудования предприятий машиностроения России. *Экономика и промышленность*. 4: 45–52.
- Ильичев В.Ю., Жукова Ю.М., Шамов И.В. 2021. Использование технологии градиентного бустинга для создания аппроксимационных моделей. *Заметки ученого*. 12-1: 62–67. EDN JPUAYV
- Кабалдин Ю.Г., Шатагин Д.А., Кузьмишина А.М. 2018. Интеллектуальное управление технологическим оборудованием предприятия в условиях цифровых производств. *Известия высших учебных заведений. Машиностроение*, 7(700): 30–41. DOI 10.18698/0536-1044-2018-7-30-41. EDN XUELJZ
- Казюлин Р.В., Неподкосова Ю.А., Чернышов Н.Г. 2024. Подход к управлению состоянием режущего инструмента станка с числовым программным управлением. *Modern Science*, 6-2: 24–29. EDN AMEQGJ.
- Конев К.А. 2022. Использование методов машинного обучения в задачах принятия решений при обеспечении качества в приборостроении. *Экономика. Информатика*, 49(4): 820–832. DOI:10.52575/2687-0932-2022-49-4-820-832
- Конев К.А., Антонов В.В. 2024. Поддержка принятия решений при обеспечении качества с использованием ситуационно-онтологического подхода. М.: Русайнс, 152. EDN SHBZGQ
- Коэлью Л., Ричарт В. 2023. Построение систем машинного обучения на языке Python. пер. с англ. А.А. Слинкина. 3-е изд., М.: ДМК Пресс 304.
- Малкина И.В. 2022. Автоматизация контроля качества геометрических параметров деталей в машиностроении. *Известия Самарского научного центра Российской академии наук*, Т. 24, № 3(107): 34–41. DOI 10.37313/1990-5378-2022-24-3-34-41. EDN DDURMC
- Матвеева Е.А., Черных О.Н. 2021. Автоматизация контроля состояния производственного оборудования. *Инфокоммуникационные технологии*, 19(1): 53–58. DOI 10.18469/ikt.2021.19.1.07. EDN VHHPMI
- Пономарев А.И. 2021. Анализ современных методов оценки состояния режущего инструмента при обработке металла. Автоматизация и управление в машино- и приборостроении: сборник научных трудов. Саратов: Саратовский государственный технический университет имени Гагарина Ю.А. 91–97. EDN KZCKIW

- Самигулина Г.А., Самигулина З.И. 2015. Разработка интегрированной OWL модели для иммуносетевого моделирования сульфаниламидов. *Современный научный вестник*, 2(1): 3–5. EDN VPAFFD.
- Стойич М., Стевич Ж., Николич А., Божичкович З. 2019. Многокритериальная модель оценки и выбора автоматически управляемых транспортных средств (AGV) для складов. *Современные проблемы транспортного комплекса России*, 9(1): 4–20. DOI 10.18503/2222-9396-2019-9-1-4-20
- Тихвинский В.И., Морозов В.А., Пономарев А.Н. 2022. Связь онтологий и метода Парето. *Научно-технический вестник Поволжья*, 6: 86–90. EDN BHESGG
- Шашок А.В. Прогнозирование стойкости и надежности токарных резцов: дис. канд. техн. наук: 05.03.01. Барнаул, 2001. 178 с. [Электронный ресурс]. URL: <https://tekhnosfera.com/prognozirovanie-stoykosti-i-nadezhnosti-tokarnyh-reztsov> (дата обращения: 14.04.2025).
- Янов Е.С., Антонычев С.В., Анцев А.В. и др. 2024. Исследование способов контроля состояния фрезерных станков на основе анализа вибрационных характеристик. *Известия высших учебных заведений. Поволжский регион. Технические науки*, 3(71): 157–166. DOI 10.21685/2072-3059-2024-3-14. EDN BCRMNH
- McKinney Wes. 2017. Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython 2nd Edition, O'Reilly Media: 724 p. ISBN 9781449319793.

References

- Antonov V.V., Konev K.A., Kulikov G.G. 2021. Transformation of the decision support system model for typical situations using intelligent and analytical methods. *Bulletin of SUSU. Series "Computer technologies, control, radio electronics"*, 21(3): 14–25 (in Russian). DOI 10.14529/ctcr210302
- Voronin A.V., Grechukhin A.I., Kalashnikov A.S. et al. 1985. Mechanization and automation of assembly in mechanical engineering. M.: Mechanical Engineering, 272 (in Russian).
- Gavrilova T.A., Khoroshevsky V.F. 2000. Knowledge bases of intelligent systems. St. Petersburg: Piter, 384 (in Russian).
- Denisenko S.A., Bulygin F.V., Pankov A.N. et al. 2023. Methodological foundations of the Pareto principle and its implementation in physics and metrology. *Competence*, 8: 15–23 (in Russian). DOI 10.24412/1993-8780-2023-8-15-23. EDN YGQTUE
- Elenew K.S., Malkova T.B., Elenew Yu.Ya., Kudryashov S.A. 2023. Approaches to clustering metal-cutting and forging and pressing equipment of mechanical engineering enterprises of Russia. *Economy and Industry*, 4: 45–52 (in Russian).
- Ilyichev V.Yu., Zhukova Yu.M., Shamov I.V. 2021. Using gradient boosting technology to create approximation models. *Notes of a scientist*, 12-1: 62–67 (in Russian). EDN JPUAYV
- Kabal'din Yu.G., Shatagin D.A., Kuzmishina A.M. 2018. Intelligent control of enterprise technological equipment in the context of digital production. *Bulletin of higher educational institutions. Mechanical engineering*, 7 (700): 30–41 (in Russian). DOI 10.18698/0536-1044-2018-7-30-41. EDN XUELJZ.
- Kazyulin R.V., Nepodkosova Yu.A., Chernyshov N.G. 2024. Approach to controlling the state of the cutting tool of a machine with numerical control. *Modern Science*, 6-2: 24–29 (in Russian). EDN AMEQGJ
- Konev K.A. 2022. Using machine learning methods in decision-making problems when ensuring quality in instrument making. *Economics. Information technologies*, 49(4): 820–832 (in Russian). DOI:10.52575/2687-0932-2022-49-4-820-832
- Konev K.A., Antonov V.V. 2024. Support for decision-making in quality assurance using a situational-ontological approach, M. Rusains, 152 (in Russian). EDN SHBZGQ
- Coelho L.P., Richart V. 2023. Building Machine Learning Systems in Python. 3rd ed., Moscow: DMK Press, 304. (trans. from English by A. A. Slinkin).
- Mal'kina I.V. 2022. Automation of quality control of geometric parameters of parts in mechanical engineering. *Bulletin of the Samara Scientific Center of the Russian Academy of Sciences*. V. 24, 3 (107): 34–41 (in Russian). DOI 10.37313/1990-5378-2022-24-3-34-41. EDN DDURMC
- Machine Learning in Manufacturing: Industrial Use Cases in 2025 [Electronic resource]. MobiDev. 2025. Access mode: <https://mobidev.biz/blog/machine-learning-application-use-cases-manufacturing-industry> (date of access: 13.04.2025).
- Matveeva E.A., Chernykh O.N. 2021. Automation of monitoring the condition of production equipment. *Infocommunication technologies*. 19(1): 53–58 (in Russian). DOI 10.18469/ikt.2021.19.1.07. EDN VHHPMI.



- Ponomarev A.I. 2021. Analysis of modern methods for assessing the condition of a cutting tool during metal processing. Automation and control in mechanical engineering and instrument making: collection of scientific papers. Saratov State Technical University: 91–97 (in Russian). EDN KZCKIW
- Samigulina G.A., Samigulina Z.I. 2015. Development of an integrated OWL model for immune network modeling of sulfonamides. *Modern Scientific Bulletin*, 2(1): 3–5 (in Russian). EDN VPAFFD
- Stojcic M., Stevich Z., Nikolic A., Bozickovic Z. 2019. Multicriteria model for evaluation and selection of automatically guided vehicles (AGV) for warehouses. *Modern problems of the transport complex of Russia*, 9(1): 4–20 (in Russian). DOI 10.18503/2222-9396-2019-9-1-4-20
- Tikhvinsky V.I., Morozov V.A., Ponomarev A.N. 2022. Relationship between ontologies and the Pareto method. *Scientific and technical bulletin of the Volga region*, 6: 86–90 (in Russian). EDN BHESGG
- Shashok A.V. 2001. Forecasting the durability and reliability of turning cutters: dis. candidate of technical sciences: 05.03.01. Barnaul: 178 (in Russian). [Electronic resource]. URL: <https://tekhnosfera.com/prognozirovanie-stoykosti-i-nadezhnosti-tokarnyh-reztsov> (date of access: 14.04.2025).
- Yanov E.S., Antonychev S.V., Antsev A.V. et al. 2024. Study of methods for monitoring the condition of milling machines based on the analysis of vibration characteristics. *News of higher educational institutions. Volga region. Technical sciences*, 3(71): 157–166 (in Russian). DOI 10.21685/2072-3059-2024-3-14. EDN BCRMNH
- McKinney Wes. 2017. Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython 2nd Edition, O'Reilly Media: 724 p. ISBN 9781449319793

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Поступила в редакцию 24.06.2025

Поступила после рецензирования 05.09.2025

Принята к публикации 08.09.2025

Received June 24, 2025

Revised September 05, 2025

Accepted September 08, 2025

ИНФОРМАЦИЯ ОБ АВТОРЕ

Конев Константин Анатольевич, кандидат технических наук, доцент, доцент кафедры автоматизированных систем управления, Уфимский университет науки и технологий, г. Уфа, Россия

INFORMATION ABOUT THE AUTHOR

Konstantin A. Konev, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Automated Control Systems, Ufa University of Science and Technology, Ufa, Russia