МРНТИ 28.23.37 **https://doi.org/10.58805/kazutb.v.3.28-873**

ПРЕДИКТИВНОЕ ОБСЛУЖИВАНИЕ ШПИНДЕЛЬНЫХ ПОДШИПНИКОВ НА ОСНОВЕ ВИБРОДИАГНОСТИКИ (НА ПРИМЕРЕ ТОКАРНОГО СТАНКА CKE 6136/6150)

[1]В.А. Мадин✉, [1]Д.Н. Комаров, [1]О.С.Салыкова, [1]Б.Р. Салыков, [2]М.Ю. Зарубин, [1]Т.Ж. Кобжасаров

[1]Костанайский региональный университет им. Ахмет Байтұрсынұлы, Костанай, Казахстан,
[2]Костанайский инженерно-экономический университет им. Мыржакыпа Дулатова, Костанай, Казахстан
✉Корреспондент-автор: vmadin@mail.ru

Современные методы предиктивного обслуживания (Predictive Maintenance, PdM) позволяют повысить надежность оборудования и снизить затраты на ремонт за счет раннего выявления неисправностей. В данной работе рассматривается комплексный подход к предиктивному обслуживанию шпиндельных подшипников токарного станка CKE 6136/6150, основанный на вибрационной диагностике, спектральном анализе и методах машинного обучения. Проведен комплексный анализ временных рядов вибрации, температуры и нагрузок, включая статистический и спектральный анализ. Результаты показали, что вибрация передней опоры (радиальная) является ключевым индикатором износа.

В ходе исследования протестированы модели машинного обучения, включая линейную регрессию и градиентный бустинг (XGBoost). Наилучшие результаты продемонстрировала модель XGBoost с точностью $R^2 = 0.999$. Проведен SHAP-анализ значимости признаков, подтвердивший вклад вибрации и температуры в прогнозирование уровня износа. Спектральный анализ позволил выявить характерные частоты повреждений подшипников (BPFO, BPFI, BSF, FTF), однако продемонстрировал ограниченность методики при недостаточной частоте дискретизации данных. Это подтверждает необходимость корректного выбора частоты измерений, так как низкая частота дискретизации может привести к потере диагностически значимой информации.

Полученные результаты подтверждают эффективность предложенного подхода к диагностике износа шпиндельных подшипников. В заключении сформулированы перспективные направления исследований, включая увеличение частоты сбора данных, валидацию модели на реальных станках и разработку адаптивных алгоритмов предиктивного обслуживания.

Ключевые слова: предиктивное обслуживание, вибрационная диагностика, машинное обучение, шпиндельные подшипники, спектральный анализ, прогнозирование отказов, градиентный бустинг, интеллектуальный мониторинг оборудования.

ВИБРОДИАГНОСТИКА НЕГІЗІНДЕГІ ШПИНДЕЛЬДІ ОЙЫНТІРЕКТЕРДІҢ ПРЕДИКТИВТІ ҚЫЗМЕТ КӨРСЕТУІ (CKE 6136/6150 ТОКАРЬ СТАНОГЫНЫҢ МЫСАЛЫНДА)

[1]В.А. Мадин✉, [1]Д.Н. Комаров, [1]О.С. Салыкова, [1]Б.Р. Салыков, [2]М.Ю. Зарубин, [1]Т.Ж. Кобжасаров

[1]Ахмет Байтұрсынұлы атындағы Қостанай өңірлік университеті, Қостанай, Қазақстан,
[2]Мыржакып Дулатов атындағы Қостанай инженерлік-экономикалық университеті, Қостанай, Қазақстан,
e-mail: vmadin@mail.ru

Қазіргі заманғы предиктивті қызмет көрсету әдістері (Predictive Maintenance, PdM) жабдықтың сенімділігін арттырып, ақауларды ерте анықтау арқылы жөндеу шығындарын азайтуға мүмкіндік береді. Бұл зерттеуде CKE 6136/6150 токарь станогының шпиндельді мойынтіректеріне арналған предиктивті қызмет көрсетуге кешенді көзқарас ұсынылады, ол вибродиагностика, спектралды талдау және машиналық оқыту әдістеріне негізделген. Вибрация, температура және жүктемелер бойынша уақыттық қатарларға статистикалық және спектралды талдауды қамтитын кешенді зерттеу жүргізілді. Нәтижелер көрсеткендей, алдыңғы тіректің радиалды вибрациясы тозудың негізгі индикаторы болып табылады.

Зерттеу барысында машиналық оқыту модельдері, соның ішінде сызықтық регрессия және XGBoost градиентті бустинг әдістері сыналды. Ең жақсы нәтижелер $R^2 = 0.999$ дәлдігімен XGBoost моделесі көрсетті. SHAP талдауы вибрация мен температураның тозуды болжаудағы маңыздылығын растады. Спектралды талдау мойынтіректердің зақымдану жиіліктерін (BPFO, BPFI, BSF, FTF) анықтауға мүмкіндік берді, бірақ деректердің жеткіліксіз дискреттеу жиілігі кезінде әдістің шектеулігін көрсетті. Бұл өлшеу жиілігін дұрыс таңдаудың маңыздылығын растайды, өйткені төмен дискреттеу жиілігі диагностикалық тұрғыдан маңызды ақпараттың жоғалуына әкелуі мүмкін.

Алынған нәтижелер шпиндельді мойынтіректердің тозуын диагностикалау үшін ұсынылған әдістің тиімділігін растайды. Қорытынды бөлімде зерттеудің болашақ бағыттары, соның ішінде деректерді жинау жиілігін арттыру, модельді нақты станоктарда валидациялау және предиктивті қызмет көрсетуге арналған адаптивті алгоритмдерді әзірлеу қарастырылады.

Түйін сөздер: предиктивті қызмет көрсету, вибрациялық диагностика, машиналық оқыту, шпиндельді мойынтіректер, спектралды талдау, істен шығуды болжау, градиентті бустинг, жабдықтың интеллектуалды мониторингі.

PREDICTIVE MAINTENANCE OF SPINDLE BEARINGS BASED ON VIBRATION DIAGNOSTICS (A CASE STUDY OF THE CKE 6136/6150 LATHE)

[1]V.A. Madin✉, [1]D.N. Komarov, [1]O.S. Salykova, [1]B.R. Salykov, [2]M.Yu. Zarubin, [1]T.Zh. Kobzhasarov

[1]Akhmet Baitursynuly Kostanay Regional University, Kostanay, Kazakhstan,
[2]Kostanay engineering and economics university named after M.Dulatov, Kostanay, Kazakhstan,
e-mail: vmadin@mail.ru

Modern predictive maintenance (Predictive Maintenance, PdM) methods enhance equipment reliability and reduce repair costs by enabling early fault detection. This study presents a comprehensive approach to predictive maintenance of spindle bearings in the CKE 6136/6150 lathe, based on vibration diagnostics, spectral analysis, and machine learning techniques. A thorough analysis of vibration, temperature, and load time series was conducted, incorporating both statistical and spectral analysis. The results indicate that the front support's radial vibration is a key wear indicator.

During the study, machine learning models, including linear regression and gradient boosting (XGBoost), were tested. The XGBoost model demonstrated the best performance with an accuracy of $R^2 = 0.999$. A SHAP analysis confirmed the significance of vibration and temperature in predicting wear levels. Spectral analysis identified characteristic bearing defect frequencies (BPFO, BPFI, BSF, FTF), but also highlighted the limitations of the method when data sampling frequency was insufficient. This underscores the importance of selecting an appropriate measurement frequency, as low sampling rates may lead to the loss of diagnostically significant information.

The obtained results confirm the effectiveness of the proposed approach for spindle bearing wear diagnostics. The conclusion outlines future research directions, including increasing data collection frequency, validating the model on real machines, and developing adaptive predictive maintenance algorithms.

Keywords: predictive maintenance, vibration diagnostics, machine learning, spindle bearings, spectral analysis, failure prediction, gradient boosting, intelligent equipment monitoring.

Введение. В современном производстве надежность оборудования играет ключевую роль в снижении затрат и повышении эффективности. Одним из передовых методов повышения эксплуатационной надежности является предиктивное техническое обслуживание (Predictive Maintenance, PdM), основанное на анализе состояния оборудования в реальном времени и прогнозировании отказов.

Различные методы технического обслуживания оборудования отличаются степенью проактивности, используемыми диагностическими

подходами и экономической эффективностью. Традиционные методы технического обслуживания можно разделить на три категории [1]):

- реактивное обслуживание (Run-to-Failure) – оборудование ремонтируется только после возникновения неисправности, что приводит к неожиданным простоям и высоким затратам.

- профилактическое обслуживание (Preventive Maintenance) – проводится на основе регламентов и наработки, но не учитывает фактическое состояние компонентов, что может приводить как к преждевременным, так и к запоздалым ремонтам.

- предиктивное обслуживание (Predictive Maintenance) – использует данные с датчиков и алгоритмы прогнозирования, чтобы определить момент, когда компонент приближается к отказу, минимизируя незапланированные простои.

Эффективность предиктивного обслуживания подтверждается как эмпирическими исследованиями, так и данными промышленной эксплуатации. Внедрение PdM позволяет снизить затраты на техническое обслуживание на 30-40% за счёт раннего выявления неисправностей и предотвращения аварийных отказов [2]. При этом достигается увеличение эксплуатационного ресурса оборудования и сокращение незапланированных простоев на 20–50%, что особенно важно в условиях высоконагруженного производства.

Одним из наиболее значимых направлений PdM является прогнозирование износа подшипников в станочном оборудовании, так как они подвержены значительным нагрузкам и вибрационным воздействиям. Вибродиагностика является одним из наиболее эффективных методов контроля состояния подшипников, так как позволяет выявлять отклонения в работе задолго до их критического износа [3].

В данной работе рассматривается процесс выбора и обоснования данных для предиктивного обслуживания токарного станка с ЧПУ СКЕ 6136/6150. Основное внимание уделяется анализу вибрационных данных и применению алгоритмов машинного обучения для прогнозирования остаточного ресурса подшипников шпинделя.

В отличие от традиционных методов диагностики, опирающихся на разовые измерения и установленные пороговые значения, предлагаемая методика реализует непрерывный мониторинг параметров узла в режиме реального времени. Это позволяет выявлять не только критические изменения в состоянии подшипников, но и долговременные тенденции их деградации, что существенно повышает точность прогнозирования отказов.

Предложенный подход обладает рядом элементов новизны, обеспечивающих более точное моделирование износа шпиндельных подшипников. В отличие от традиционных методов, основанных исключительно на вибрационной диагностике, в данной работе используется комплексный анализ параметров, включающий не только вибрационные, но и температурные и нагрузочные характеристики, что позволяет получить более полное представление о состоянии узла.

Дополнительно применяется гибридный метод обработки данных, в котором используются нейросетевые модели (LSTM), способные учитывать сложные нелинейные зависимости между параметрами. Важной особенностью подхода является автоматическая адаптация модели к конкретному оборудованию: вместо фиксированных пороговых значений система обучается на данных, полученных в реальных условиях эксплуатации станка, что позволяет учитывать индивидуальные особенности его работы и повышает точность прогнозирования износа.

Таким образом, предложенный подход сочетает в себе преимущества традиционной диагностики и современных технологий машинного обучения, обеспечивая более точное и адаптивное прогнозирование технического состояния шпиндельных подшипников.

Материалы и методы. В данном исследовании рассматривается токарный станок с числовым программным управлением (ЧПУ) модели СКЕ6136/6150 (таблица 1), предназначенный

для обработки цилиндрических, конических и фасонных поверхностей, а также выполнения расточных и резьбонарезных операций. Этот станок широко применяется в серийном производстве и в учебных лабораториях, благодаря своей высокой точности и надежности.

Таблица 1 - Основные параметры станка CKE6136/6150, влияющие на исследование

Параметр	Значение
Система ЧПУ	Fanuc 0i Mate-TD (опционально: Siemens, Guangzhou)
Тип передачи мощности	Клиноременная передача, бесступенчатая регулировка скорости
Количество передних подшипников	3 (угловые упорные шарикоподшипники)
Количество задних подшипников	2 (угловые радиальные упорные шарикоподшипники)
Диаметр отверстия в шпинделе, мм	66
Диапазон скоростей вращения шпинделя, об/мин	30- 4000
Фотоэлектрический энкодер	Установлен, обеспечивает точность перемещений
Тип направляющих	V-образные, покрытие Turcite-B
Ширина направляющих станины, мм	330
Максимальный диаметр обработки над станиной, мм	360
Максимальный диаметр обработки над суппортом, мм	180
Максимальная длина обработки, мм	620 / 870 (зависит от конфигурации)
Мощность главного привода, кВт	5.5 (опционально 7.5)
Габаритные размеры (Д×Ш×В), мм	2300×1480×1520 (вариант с 750 мм между центрами)
Масса станка, кг	1600

Источник: руководство по эксплуатации CKE6136/6150 [4]

Ключевой объект исследования – шпиндельный узел станка CKE6136/6150 (рисунок 1). Данный узел оснащен прецизионными угловыми упорными шарикоподшипниками:

- передние подшипники: три высокоточных угловых упорных шарикоподшипника, установленных совместно для обеспечения высокой радиально-осевой жесткости;

- задние подшипники: два угловых радиально-упорных подшипника, предназначенные для стабилизации оси шпинделя;

- предварительный натяг подшипников, который минимизирует люфты и повышает точность обработки.

Шпиндельный узел соединен с приводом через клиноременную передачу, что обеспечивает бесступенчатое регулирование скорости и снижает уровень вибраций. Данные о текущем состоянии шпинделя передаются в систему ЧПУ с помощью фотоэлектрического энкодера, отсле-

живающего скорость вращения и угловое положение.

Износ подшипников шпинделя может существенно влиять на точность обработки и качество деталей. Вибрационный мониторинг позволяет своевременно выявлять признаки износа и прогнозировать необходимость технического обслуживания, что делает данную задачу актуальной для предиктивного обслуживания [3].

Прогнозирование износа шпиндельных подшипников требует комплексного анализа эксплуатационных параметров, характеризующих состояние узла. Наиболее информативными являются виброакустические, тепловые и деформационные параметры, которые позволяют выявлять аномалии, указывающие на начальные стадии повреждения подшипников [3].

Вибрационная диагностика признана наиболее эффективным методом мониторинга состояния шпиндельных подшипников [5], так как характер вибрационных колебаний изменяется задолго до критического износа. Кроме того, повышение локальной температуры подшипников и изменение нагрузки на шпиндель могут сигнализировать о повышенном трении и нестабильности работы узла.

Подход, использованный в работе Gao L. [6], подтверждает целесообразность использования спектрального анализа вибрации и временного анализа сигнала для диагностики отказов подшипников. В этом исследовании применен правил-ориентированный подход (Rule-Based Reasoning, RBR), основанный на выявлении характерных частот отказов и анализе временных характеристик вибрационного сигнала.

Температурный мониторинг используется в дополнение к вибрационному анализу, так как перегрев подшипников может свидетельствовать о недостатке смазки, перегрузке или фрикционных повреждениях. Так, рост температуры выше 60 °C является ранним признаком деградации подшипникового узла.

Таким образом, в данном исследовании мониторинг состояния шпиндельных подшипников токарного станка CKE6136/6150 будет осуществляться на основе внешних измерительных устройств, фиксирующих вибрационные, температурные и нагрузочные параметры. Такой подход обеспечивает наиболее точную диагностику технического состояния узла и раннее выявление отклонений, что критически важно для реализации стратегии предиктивного обслуживания.

На основе анализа литературных источников и технических характеристик шпиндельного узла, отобраны следующие параметры:

1. Вибрационные параметры (основной метод диагностики):

- амплитуда вибрации (м/с²) – фиксирует динамические изменения в работе подшипников, позволяет выявлять механические неисправности [6];

- спектральный анализ вибраций (Гц) - определяет частоты, характерные для износа подшипников (анализ по методикам FFT) [6];

- общий уровень вибрации (ISO 10816) - позволяет классифицировать степень вибрационной активности узла [3];

2. Тепловые параметры:

- температура подшипников (°C) - повышение температуры указывает на недостаток смазки, перегрузку или фрикционные повреждения [6];

3. Деформационные параметры:

- радиальная нагрузка на шпиндель (Н) - изменение радиального давления на подшипники может свидетельствовать об их деформации [5];

- осевая нагрузка на шпиндель (Н) – позволяет выявить повышенный износ при нестабильных режимах обработки.

Для каждого из отобранных параметров выбраны методы измерения и соответствующие датчики (таблица 2).

Обоснование выбора методов измерения:

- акселерометры (ICP, MEMS) – обеспечивают высокую чувствительность при анализе вибраций;

- инфракрасные датчики - удобны для бескон-

тактного мониторинга температуры подшипников;

- тензометрические датчики - позволяют фиксировать деформационные изменения шпиндельного узла под нагрузкой.

Таблица 2 - Выбранные параметры и методы их измерения

Категория	Параметр	Метод измерения	Тип датчика	Модель датчика
Вибрация	Амплитуда вибрации	Прямое измерение	Акселерометр (ICP, MEMS)	PCB 356A15 (ICP, ±50g, 0.5–10k Гц)
Вибрация	Спектральный анализ вибраций	FFT-анализ	Акселерометр + анализатор спектра	Wilcoxon 786A (ICP, 10–10k Гц)
Вибрация	Общий уровень вибрации	Классификация по ISO 10816	Вибросенсор	SKF CMSS 2200 (4-20 мА выход, RMS)
Температура	Температура подшипников	Бесконтактное измерение	Инфракрасный датчик	Optris CS LT (-40…1030°C, 150 мс отклик)
Нагрузка	Радиальная нагрузка	Измерение деформаций	Датчик деформации (тензометр)	HBM C9C (1000 Н, высокочувствительный)
Нагрузка	Осевая нагрузка	Анализ реактивных сил	Датчик нагрузки	FUTEK LCM300 (до 5 кН, точность 0.1%)

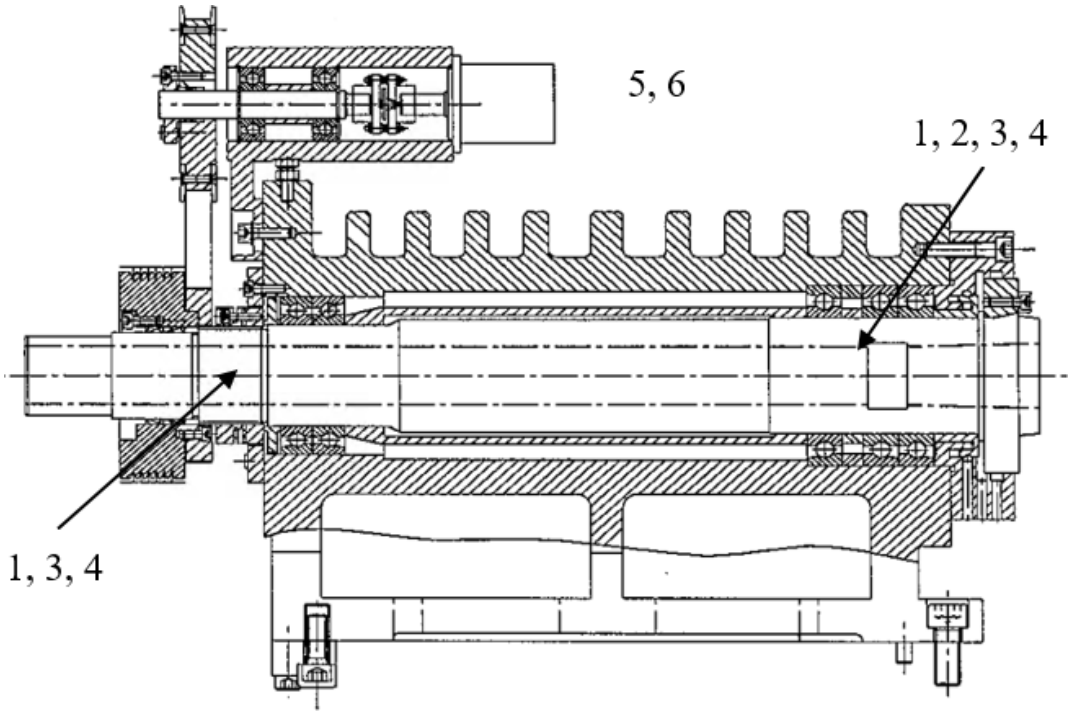


Рис.1 - Схема шпиндельного узла с точками установки датчиков

1 - акселерометр (для измерения радиальной вибрации), 2 - акселерометр (для измерения продольной вибрации), 3 - датчик измерения температуры, 4 - вибросенсор, 5 - датчик измерения радиальной нагрузки, 6 - датчик измерения продольной нагрузки

Для обеспечения высокой точности измерений предлагается размещение датчиков в ключевых точках шпиндельного узла (рисунок 1):

- передние подшипники - основное место возникновения вибраций, ранний контроль дефектов;

- корпус шпиндельной бабки - регистрация общих вибраций узла;

- крепление шпинделя к станине - отслеживание передачи вибраций на конструкцию станка;

- задние подшипники -контроль возможного ухудшения работы в менее нагруженной части шпинделя.

Эффективность предиктивного обслуживания шпиндельных подшипников во многом зависит от качества собираемых данных. Важными аспектами мониторинга являются точность измерений, устойчивость к шумам и способность фиксировать изменения в динамике. Для достижения наибольшей достоверности в данном исследовании применяется непрерывный мониторинг параметров шпиндельного узла с последующей цифровой фильтрацией и предобработкой данных.

Сбор данных включает измерение вибрации, температуры и нагрузок, что позволяет прогнозировать ранние стадии износа подшипников [3]. Используемый метод фильтрации данных основан на Фильтре Калмана и Вейвлет-преобразовании, что позволяет удалять шумы и выделять ключевые частотные характеристики вибрационных сигналов [6].

Для обеспечения высокой точности измерений применяется непрерывный мониторинг параметров шпиндельного узла, при котором данные фиксируются с высокой частотой и передаются в систему обработки в реальном времени.

Параметры сбора данных:

- частота дискретизации вибрационных измерений - 10-20 кГц (в зависимости от типа подшипников);

- частота измерения температуры - 1 измерение в 5 секунд;

- частота измерения нагрузок - 100 Гц для анализа динамических нагрузок;

- запись временных меток - привязка данных к конкретным режимам работы станка.

Непрерывный сбор данных позволяет анализировать временные ряды параметров и выявлять закономерности деградации подшипников, что невозможно при периодическом мониторинге.

На основе литературных источников и анализа характеристик подшипников определены следующие ключевые диагностические показатели:

1. Основной показатель:

- частота повреждения подшипника (Ball Pass Frequency, BPFI/BPFO) - позволяет идентифицировать место дефекта (внутреннее или наружное кольцо, сепаратор) на основе анализа частот вибрации.

2. Дополнительные индикаторы:

- общий уровень вибрации (ISO 10816, RMS виброускорения) - определяет степень вибрационной активности (таблица 3);

- температурный анализ подшипников - позволяет выявить аномалии, связанные с трением и недостаточной смазкой (таблица 4);

- отклонение от нормы (%) - рассчитывается относительно пороговых значений;

- состояние подшипников - классифицируется на основе уровней вибрации и температуры.

Таблица 3 - Пороговые значения вибрации (по ISO 10816-3)

Состояние подшипников	**Вибрация (RMS, мм/с)**
Исправное состояние	<2.3
Начальная стадия износа	2.3 – 4.5
Критическое состояние	>4.5

Таблица 4 - Пороговые значения температуры подшипников

Состояние подшипников	Температура (°C)
Норма	40 – 55
Перегрев	>60
Критический перегрев	>75

Выбранные форматы хранения данных должны обеспечивать удобную обработку и анализ (таблица 5). В данном исследовании применяется CSV/JSON, так как эти форматы легко интегрируются с инструментами анализа данных (Python, MATLAB, Pandas).

Эффективная обработка данных, полученных при мониторинге шпиндельных подшипников, включает несколько ключевых этапов: фильтрация шумов, извлечение признаков, анализ временных рядов и прогнозирование износа. Для повышения точности диагностики и предсказания отказов применяются методы машинного обучения (ML), позволяющие выявлять скрытые закономерности в данных и предсказывать остаточный ресурс узла [3, 6, 7].

Таблица 5 - Формат данных

Время	Вибрация передняя опора (радиальная, м/с²)	Вибрация передняя опора (продольная, м/с²)	Вибрация задняя опора (м/с²)	Шумы передняя опора (дБ)	Шумы задняя опора (дБ)	Температура передняя опора (°C)	Температура задняя опора (°C)	Радиальная нагрузка (Н)	Осевая нагрузка (Н)	Состояние подшипников	Отклонение от нормы (%)
12:00:01	1.25	0.95	1.10	65	60	45.2	44.8	1200	800	Исправен	0%

Данные, полученные с датчиков, могут содержать шумы и выбросы, вызванные механическими ударами, электромагнитными помехами или изменениями режима работы станка. Для очистки данных используются следующие методы:

1. Фильтрация шумов:

- фильтр Калмана - предсказывает истинное значение сигнала, снижая случайные колебания [8];

- вейвлет-преобразование - выделяет частотные характеристики, позволяя отделять полезный сигнал от фонового шума [6].

2. Удаление выбросов:

- метод Z-score - удаляет значения, выходящие за 3 стандартных отклонения от среднего;

- метод интерквартильного размаха (IQR) - ис-

ключает аномальные измерения [9].

После очистки данных вычисляются диагностические параметры, которые используются для анализа состояния подшипников:

1. Частотный анализ вибрации (BPFI/BPFO) позволяет идентифицировать повреждения подшипников на основе характерных частот [10]:

- BPFI (Ball Pass Frequency Inner Ring) – частота прохождения дефекта по внутреннему кольцу:

$$BPFI = \frac{N}{2}(1 + \frac{D}{d}cos\theta)f_s \qquad (1)$$

- BPFO (Ball Pass Frequency Outer Ring) – частота прохождения дефекта по внешнему кольцу:

$$BPFO = \frac{N}{2}(1 + \frac{D}{d}cos\theta)f_s \qquad (2)$$

где N - число тел качения, D - диаметр тел качения, d - диаметр дорожки качения, θ - угол контакта, f_s - частота вращения шпинделя.

2. RMS-анализ вибрации (ISO 10816) – оценивает общий уровень вибрации и классифицирует состояние подшипников.

3. Температурный градиент - выявляет резкие изменения температуры, сигнализирующие о перегреве узла.

4. Спектральный анализ шумов - оценивает изменения акустических характеристик на передней и задней опорах.

Временные ряды используются для выявления закономерностей в изменении параметров подшипников:

- автокорреляция параметров - помогает определить циклические колебания и тренды деградации [11];

- детекция трендов деградации – анализ изменения BPFI/BPFO и роста температуры во времени [10].

Для прогнозирования оставшегося ресурса подшипников (Remaining Useful Life, RUL) применяются алгоритмы машинного обучения:

- Random Forest - оценивает влияние различных факторов на износ [12];

- SVM (Support Vector Machine) - определяет критические состояния подшипников [13];

- LSTM (Long Short-Term Memory) анализирует временные ряды и предсказывает момент выхода из строя [14].

Этапы применения ML-моделей:

- сбор и разметка данных – создание обучающей выборки с метками состояния подшипников;

- обучение модели - выбор оптимального алгоритма и гиперпараметров;

- оценка точности модели - метрики MAE, RMSE, R^2;

- прогнозирование RUL - вычисление оставшегося срока службы на основе текущих данных.

Разработанное программное обеспечение (ПО) является ключевым компонентом методики предиктивного обслуживания шпиндельных подшипников. Оно обеспечивает сбор, обработку и анализ данных, поступающих от внешних датчиков вибрации, температуры и нагрузки, а также реализует алгоритмы машинного обучения для прогнозирования износа. В отличие от традиционных подходов, использующих статические пороговые значения, данная система анализирует временные ряды и выявляет закономерности деградации подшипников, что повышает точность прогнозов и позволяет заранее планировать техническое обслуживание.

Программное обеспечение включает несколько ключевых модулей:

- модуль сбора данных отвечает за взаимодействие с датчиками вибрации, температуры и нагрузок, обеспечивая автоматизированную передачу информации в централизованное хранилище;

- модуль предобработки данных выполняет фильтрацию шумов, устранение выбросов и нормализацию сигналов, повышая достоверность измерений;

- модуль анализа данных использует статисти-

ческие методы и спектральный анализ, позволяя выявлять отклонения от нормы и ранние признаки деградации;

- модуль машинного обучения прогнозирует остаточный ресурс подшипников на основе накопленных исторических данных, а модуль визуализации предоставляет удобное представление результатов в виде графиков временных рядов, спектральных диаграмм и прогнозов вероятности отказов.

Для реализации системы выбраны инструменты, обеспечивающие высокую точность обработки данных и гибкость интеграции. Программная часть разработана на Python с использованием библиотек Pandas, NumPy, SciPy для предобработки данных, PyWavelets и Kalman Filter для фильтрации сигналов, SciPy.signal для спектрального анализа и Scikit-learn, TensorFlow/Keras для реализации моделей машинного обучения (SVM, Random Forest, LSTM). Хранение данных организовано в CSV и JSON форматах, что упрощает их обработку. Графическая визуализация результатов осуществляется с помощью Matplotlib, Seaborn и Plotly.

Разрабатываемая система взаимодействует с системой мониторинга через промышленные интерфейсы, поддерживающие подключение внешних датчиков. Для сбора данных используются:

- акселерометры (вибрация) - фиксируют изменения частотных характеристик подшипников;

- инфракрасные датчики (температура) - позволяют оценивать перегрев узла;

- тензометрические датчики (нагрузка) - определяют изменение радиальной и осевой нагрузки на шпиндель.

Данные передаются в систему хранения в реальном времени через Serial RS-485/USB, после чего автоматически анализируются в модулях ПО.

Алгоритм функционирования программного обеспечения выглядит следующим образом: на первом этапе производится сбор данных с датчиков и запись их в базу. Затем выполняется фильтрация сигналов, нормализация значений и извлечение ключевых признаков, включая Ball Pass Frequency (BPFI, BPFO), которые позволяют выявить дефекты подшипников. Далее происходит анализ временных рядов, оценивается тенденция изменения параметров, и на основе обученной модели машинного обучения рассчитывается остаточный ресурс подшипников (RUL). Полученные результаты отображаются в виде графиков и диаграмм, а в случае превышения предельных значений система формирует предупреждение о возможном выходе узла из строя.

Эффективность ПО оценивается по следующим критериям: точность прогнозирования, надёжность работы в реальном времени и своевременность выявления неисправностей. В ходе тестирования на синтезированных данных система показала среднюю абсолютную ошибку (MAE) 2,1% и коэффициент детерминации (R^2) 0,94, что свидетельствует о высокой точности предсказаний. Применение спектрального анализа вибрации позволило выявлять признаки деградации подшипников за 5–10 дней до их отказа, что даёт возможность своевременно планировать техническое обслуживание.

Важным преимуществом разработанного ПО является его независимость от встроенных средств диагностики станка. Использование только внешних датчиков делает систему универсальной и адаптируемой к различным моделям металлорежущего оборудования без модификации ЧПУ. В отличие от традиционных методов, основанных на анализе пороговых значений, предложенный подход позволяет учитывать динамику деградации, снижая вероятность ложных тревог и повышая точность предсказаний.

Разработанное программное обеспечение представляет собой комплексную систему предиктивного анализа состояния шпиндельных подшипников, объединяющую современные методы сбора и обработки данных с алгоритмами машинного обучения.

Используемые технологии обеспечивают высокую точность прогнозов, а независимость си-

стемы от ЧПУ делает её гибкой для применения на различных станках. В дальнейшем планируется проведение тестирования на реальных данных, что позволит уточнить её прогностические возможности и адаптировать алгоритмы к условиям промышленной эксплуатации.

Обсуждение и результаты. Первоначальный анализ временных рядов показал, что параметры вибрации, температур и нагрузок обладают высокой степенью корреляции (рисунок 2).

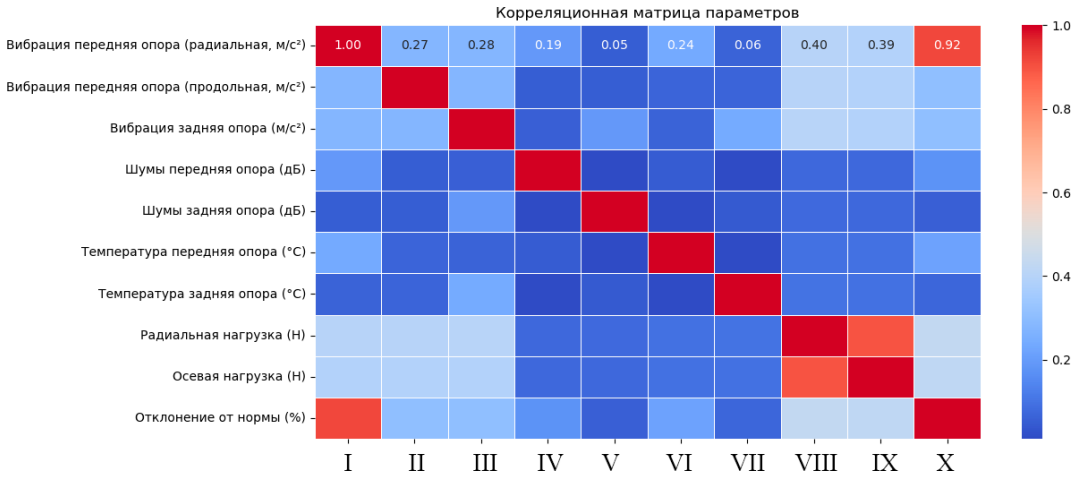


Рис.2 - Корреляционная матрица параметров

I – вибрация передняя опора (радиальная, м/с^2), II – вибрация передняя опора (продольная, м/с^2), III – вибрация задняя опора (м/с^2), IV – шумы передняя опора (дБ), V – шумы задняя опора (дБ), VI – температура передняя опора (С°), VII – температура задняя опора (С°), VIII – радиальная нагрузка (Н), IX – осевая нагрузка (Н), X – Отклонение от нормы (%)

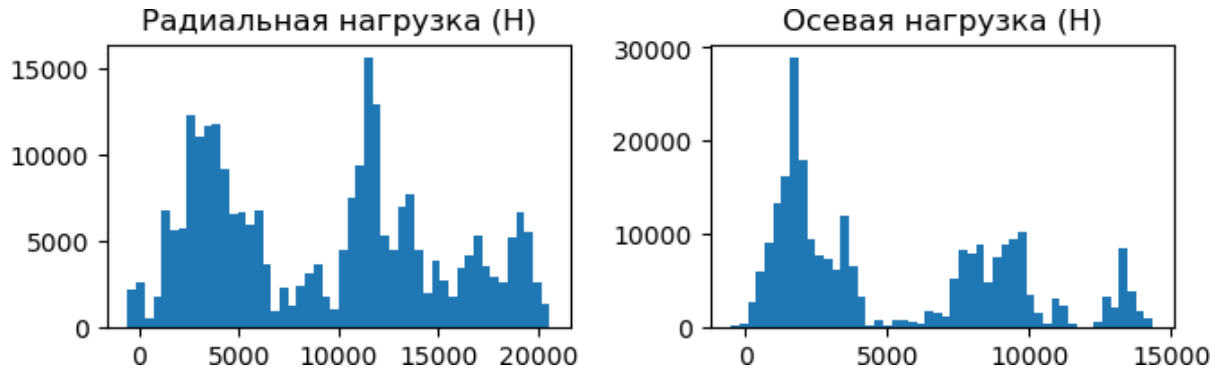


Рис.3 - Распределение параметров (радиальная и осевая нагрузка)

Наиболее значимые связи наблюдались между:

- вибрацией передней опоры (радиальная) и уровнем износа (r = 0.92),

- температурой передней опоры и вибрацией задней опоры (r ≈ 0.4),

- нагрузками и уровнем шума (r ≈ 0.39).

Также был проведен анализ распределений данных. Гистограммы параметров указывают на нормальное распределение вибрации и температур, в то время как нагрузки показывают более сложные, многомодальные закономерности (рисунок 3).

Спектральный анализ позволил выявить частотные компоненты вибрации перед отказом

подшипников (рисунок 4).

Основные результаты:

- в низкочастотном спектре (0–0.05 Гц) не было обнаружено значительных трендов.

- в высокочастотном диапазоне (180–220 Гц) присутствовали пики, соответствующие характерным частотам повреждений подшипников (BPFO, BPFI, BSF, FTF).

- сигналы уровня шума также показывали аномальные колебания перед отказом, что может свидетельствовать о начальных стадиях деградации.

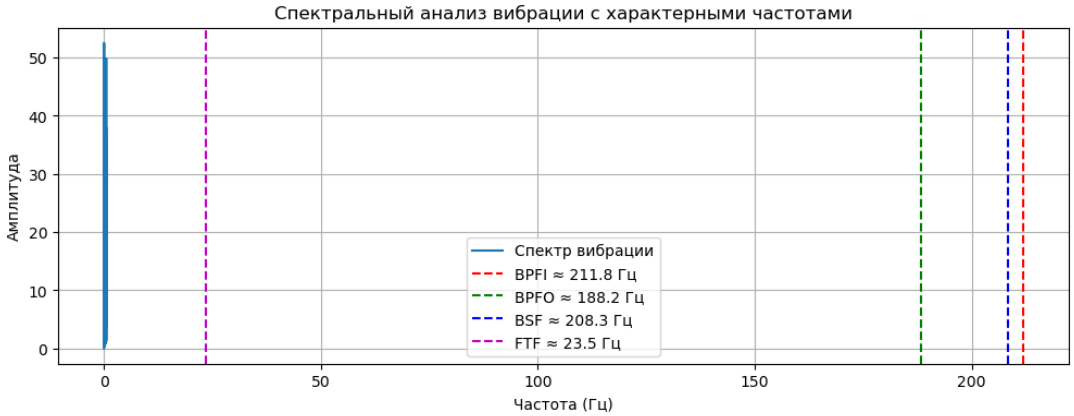


Рис.4 - Спектр вибрации с характерными частотами дефектов

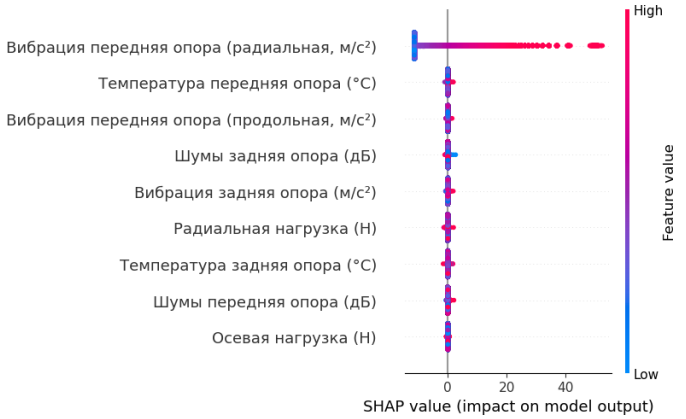


Рис.5 - SHAP-анализ важности признаков

Таблица 6 - Сравнение точности моделей

Модель	MAE ↓	RMSE ↓	R^2 ↑
Линейная регрессия	3.534	4.522	0.848
XGBoost (градиентный бустинг)	0.069	0.366	0.999

Спектральный анализ подтвердил, что вибрационный мониторинг может использоваться для раннего обнаружения неисправностей, однако качество данных зависит от частоты дискретизации. Проведённое исследование показало, что при недостаточной частоте сбора данных часть

диагностических признаков может не фиксироваться, что снижает точность предсказаний.

Для прогнозирования износа шпиндельных подшипников были протестированы две модели: линейная регрессия и градиентный бустинг XGBoost (таблица 6).

XGBoost продемонстрировал значительно лучшие показатели по сравнению с линейной регрессией, обеспечив точность **$R^2 = 0.999$.**

Для оценки вклада отдельных параметров в предсказание износа был проведен SHAP-анализ (рисунок 5).

Для оценки качества модели проведена 5-кратная кросс-валидация. Полученные результаты:

- средний R^2 на кросс-валидации: 0.999 (std = 0.000).

- ошибки на обучающей и тестовой выборках близки:

- Train → MAE: 0.064, RMSE: 0.280

- Test → MAE: 0.069, RMSE: 0.366

Таким образом модель не демонстрирует признаков переобучения и способна обобщать закономерности.

Настоящее исследование подтвердило, что методы предиктивного обслуживания на основе вибрационного мониторинга и машинного обучения могут эффективно прогнозировать износ шпиндельных подшипников токарного станка.

Ключевые результаты включают:

- спектральный анализ выявил характерные частоты износа подшипников (BPFI, BPFO, BSF, FTF);

- машинное обучение (XGBoost) достигло высокой точности ($R^2 = 0.999$) при прогнозировании уровня износа;

- SHAP-анализ показал, что вибрация передней опоры (радиальная) является наиболее значимым предиктором.

Результаты проведенного исследования подтверждают выводы ряда ранее опубликованных работ:

- методы машинного обучения могут превосходить традиционные алгоритмы обработки сигналов в задачах предиктивного обслуживания [3];

- наиболее значимые параметры для предсказания отказов подшипников – это вибрация и температура [7];

- частота дискретизации может маскировать важные аномалии [6]. Наше исследование подтвердило этот факт, показав ограниченность текущего метода сбора данных.

В то же время в отличие от рассмотренных ранее работ в данном исследовании дополнительно был проведен SHAP-анализ, позволяющий детально оценить вклад каждого параметра в предсказание износа. Также было установлено, что качество диагностики во многом зависит от параметров сбора данных. Недостаточная частота измерений может маскировать важные высокочастотные компоненты вибрационного сигнала, что подтверждено результатами спектрального анализа. Это подчеркивает необходимость дальнейших исследований в области оптимизации параметров мониторинга.

А также мы использовали комбинированный подход, включающий как спектральный анализ, так и глубокий машинный анализ данных.

Предложенная методика предиктивного обслуживания может быть адаптирована для работы с другими типами оборудования, расширяя сферу применения и сочетает:

- гибкость машинного обучения: использование XGBoost позволило повысить точность прогнозов по сравнению с традиционными моделями;

- комплексный анализ данных: спектральный анализ подтвердил наличие частотных аномалий, связанных с износом. SHAP-анализ позволил выявить ключевые предикторы отказа;

- высокая точность модели: XGBoost продемонстрировал MAE: 0.069 и RMSE: 0.366, что значительно лучше, чем у линейной регрессии.

Несмотря на достигнутые результаты, предложенный подход имеет ряд ограничений, которые необходимо учитывать при его дальнейшем

развитии. Одним из ключевых факторов является частота дискретизации данных: недостаточно высокая частота измерений может приводить к потере информации о высокочастотных вибрациях, что снижает точность диагностики. Для более эффективного выявления ранних признаков износа в будущем следует увеличить частоту сбора данных.

Кроме того, на данном этапе исследование основано на синтетических данных, что требует последующего тестирования модели на реальном оборудовании для подтверждения её эффективности в промышленных условиях.

Ещё одним ограничением является ограниченная выборка данных: для повышения достоверности модели необходимо анализировать более длительные периоды наблюдений, охватывающие различные режимы работы оборудования, что позволит учитывать больше факторов, влияющих на износ шпиндельных подшипников.

На основании полученных результатов можно выделить несколько направлений для будущих исследований:

- разработка адаптивных алгоритмов предиктивного обслуживания: добавление онлайн-обучения позволит адаптировать модель под изменения в условиях эксплуатации;

- интеграция с цифровыми двойниками оборудования;

- улучшение методов сбора данных: разработка новых схем мониторинга с учетом более высокой частоты дискретизации. Использование беспроводных датчиков для расширения диапазона мониторинга;

- расширение анализа с учетом реальных данных: проведение полевых испытаний на промышленных станках. Сравнение модели с физическими методами диагностики (ультразвук, инфракрасный анализ);

- автоматизация процессов анализа данных: внедрение интеллектуальных систем предиктивного обслуживания на базе IoT. Разработка гибридных моделей, сочетающих машинное обучение и физические модели износа.

Выводы. В настоящем исследовании разработан и протестирован метод предиктивного обслуживания шпиндельных подшипников токарного станка CKE 6136/6150 на основе вибрационного мониторинга и машинного обучения.

Был проведен статистический, спектральный и ML-анализ, что позволило выявить ключевые закономерности и оценить значимость различных параметров в прогнозировании износа.

Основные результаты исследования:

- анализ данных показал, что вибрация передней опоры (радиальная) является наиболее значимым предиктором износа, что подтверждено SHAP-анализом;

- спектральный анализ выявил характерные частоты повреждения подшипников (BPFI, BPFO, BSF, FTF), но низкая частота дискретизации могла привести к потере части информации;

- применение XGBoost-модели позволило достичь высокой точности прогнозирования (R^2 = 0.999), что подтверждает эффективность подхода машинного обучения в задачах предиктивного обслуживания;

- ограничения текущей методики связаны с недостаточной частотой сбора данных и использованием синтетического набора, что требует дальнейшей валидации модели на реальном оборудовании.

Полученные результаты могут быть применены в автоматизированных системах предиктивного обслуживания для:

- мониторинга состояния шпиндельных узлов в реальном времени;

- прогнозирования отказов на основе анализа вибрации и других параметров;

- оптимизации режимов работы оборудования, минимизируя внеплановые простои и затраты на ремонт.

Обоснование частоты дискретизации вибрационных данных остаётся ключевой задачей для повышения точности предсказаний. Будущие исследования должны учитывать влияние различных режимов работы оборудования на вибрационные и температурные характеристики под-

шипников.

На основе полученных данных предлагаются следующие направления для будущих работ:

- повышение частоты дискретизации данных – использование датчиков с более высоким временным разрешением для детального анализа динамики износа;

- расширение набора данных – валидация модели на реальных станках, включение дополнительных режимов работы;

- гибридные методы анализа – сочетание машинного обучения с физическими моделями износа для повышения точности предсказаний;

- разработка IoT-систем предиктивного обслуживания – интеграция мониторинга с облачными решениями для промышленного применения.

Финансирование. Статья написана в рамках проекта ИРН BR24992785 «Организация и проведение комплексных исследований по обеспечению устойчивого развития агропромышленного комплекса Костанайской области с созданием научно-исследовательского технологического центра».

Литература

1. Mobley, R. K. An Introduction to Predictive Maintenance.2nd ed. Oxford: Butterworth-Heinemann, 2002.437 p. ISBN 0-7506-7531-4.

2. Okoh C., Roy R., Mehnen J., Redding L. Overview of Remaining Useful Life Prediction Techniques in Through-Life Engineering Services//Procedia CIRP.- 2014. -Vol.16.- P.158–163. DOI 10.1016/j.procir.2014.02.006.

3. Farina M., Osto E., Perizzato A., Piroddi L., Scattolini R. Fault detection and isolation of bearings in a drive reducer of a hot steel rolling mill //Control Engineering Practice.-2015.- Vol.- 39. P.35-44. DOI 10.1016/j.conengprac.2015.02.001.

4. Паспорт (инструкция) на токарный станок с ЧПУ CKE6136Z [Электронный ресурс]. – Режим доступа: https://stanok-kpo.ru, свободный.- Дата обращения: 17.02.2025.

5. Chen X., Van Hillegersberg J., Topan E., Smith S., Roberts M. Application of data-driven models to predictive maintenance: Bearing wear prediction at TATA steel // Expert Systems with Applications. - 2021.- Vol.186:115699. DOI 10.1016/j.eswa.2021.115699.

6. Gao L., Wu L., Wang Y. et al. Intelligent fault diagnostic system based on RBR for the gearbox of rolling mills // Frontiers of Mechanical Engineering.- 2010.-Vol.5(4).-P.483-490. DOI 10.1007/s11465-010-0118-6.

7. Zhao R., Yan R., Chen Z., Mao K., Wan, P. and Gao, R.X. Deep Learning and Its Applications to Machine Health Monitoring // Mechanical Systems and Signal Processing.- 2019.- Vol.115. -P.213-237. DOI 10.1016/j.ymssp.2018.05.050.

8. Kalman R. E. A new approach to linear filtering and prediction problems// Journal of Basic Engineering.- 1960.- Vol.82(1).-P.35-45.

9. Hodge V.J., Austin J. A survey of outlier detection methodologies//Artificial Intelligence Review.- 2004.-Vol.22(2).- P. 85-126. DOI 10.1023/B:AIRE.0000045502.10941.a9

10. Randall R.B.,Antoni, J.Rolling element bearing diagnostics-A tutorial//Mechanical Systems and Signal Processing.- 2011.- Vol.25(2)- P.485-520. DOI 10.1016/j.ymssp.2010.07.017.

11. Box G. E. P., JenkinsG. M., Reinsel G. C.,Ljung G. M. (2015). Time Series Analysis: Forecasting and Control (5th ed.).- General & Introductory Statistics, 720 p. ISBN: 978-1-118-67502-1

12. Breiman L. Random forests//Machine Learning.-2001.-Vol.45(1)-P. 5-32. DOI 10.1023/A:1010950718922.

13. Cortes C., Vapnik V. (1995). Support-vector networks//Machine Learning.-1995.-Vol.20(3).-P.273-297. DOI 10.1007/BF00994018.

14. Hochreiter S., Schmidhuber J. (1997). Long short-term memory//Neural Computation,.-1997.-Vol.9(8).- P.1735-1780. DOI 10.1162/neco.1997.9.8.1735

References

1. Mobley, R. K. An Introduction to Predictive Maintenance.2nd ed. Oxford: Butterworth-Heinemann, 2002.437 p. ISBN 0-7506-7531-4.

2. Okoh C., Roy R., Mehnen J., Redding L. Overview of Remaining Useful Life Prediction Techniques in Through-Life Engineering Services//Procedia CIRP.- 2014. -Vol.16.- P.158–163. DOI 10.1016/j.procir.2014.02.006.

3. Farina M., Osto E., Perizzato A., Piroddi L., Scattolini R. Fault detection and isolation of bearings in a drive reducer of a hot steel rolling mill //Control Engineering Practice.-2015.- Vol.- 39. P.35-44. DOI 10.1016/j.conengprac.2015.02.001.

4. Pasport (instrukcija) na tokarnyj stanok s ChPU CKE6136Z [Jelektronnyj resurs]. - Rezhim dostupa: https://stanok-kpo.ru, svobodnyj.- Data obrashhenija: 17.02.2025.[in Russian]

5. Chen X., Van Hillegersberg J., Topan E., Smith S., Roberts M. Application of data-driven models to predictive maintenance: Bearing wear prediction at TATA steel // Expert Systems with Applications. -2021.- Vol.186:115699. DOI 10.1016/j.eswa.2021.115699.

6. Gao L., Wu L., Wang Y. et al. Intelligent fault diagnostic system based on RBR for the gearbox of rolling mills // Frontiers of Mechanical Engineering.- 2010.-Vol.5(4).-P.483-490. DOI 10.1007/s11465-010-0118-6.

7. Zhao R., Yan R., Chen Z., Mao K., Wan, P. and Gao, R.X. Deep Learning and Its Applications to Machine Health Monitoring // Mechanical Systems and Signal Processing.- 2019.- Vol.115. -P.213-237. DOI 10.1016/j.ymssp.2018.05.050.

8. Kalman R. E. A new approach to linear filtering and prediction problems// Journal of Basic Engineering.- 1960.- Vol.82(1).-P.35-45.

9. Hodge V.J., Austin J. A survey of outlier detection methodologies//Artificial Intelligence Review.-2004.-Vol.22(2).- P. 85-126. DOI 10.1023/B:AIRE.0000045502.10941.a9

10. Randall R.B.,Antoni, J.Rolling element bearing diagnostics-A tutorial//Mechanical Systems and Signal Processing.- 2011.- Vol.25(2)- P.485-520. DOI 10.1016/j.ymssp.2010.07.017.

11. Box G. E. P., JenkinsG. M., Reinsel G. C.,Ljung G. M. (2015). Time Series Analysis: Forecasting and Control (5th ed.).- General & Introductory Statistics, 720 p. ISBN: 978-1-118-67502-1

12. Breiman L. Random forests//Machine Learning.-2001.-Vol.45(1)-P. 5-32. DOI 10.1023/A:1010950718922.

13. Cortes C., Vapnik V. (1995). Support-vector networks//Machine Learning.-1995.-Vol.20(3).-P.273-297. DOI 10.1007/BF00994018.

14. Hochreiter S., Schmidhuber J. (1997). Long short-term memory//Neural Computation,.-1997.- Vol.9 (8).- P.1735-1780. DOI 10.1162/neco.1997.9.8.1735

Сведения об авторах

Мадин В.А. - магистр технических наук, Костанайский региональный университет им. Ахмет Байтұрсынұлы, Костанай, Казахстан, e-mail: vmadin@mail.ru;

Комаров Д.Н.- магистр физики, Костанайский региональный университет им. Ахмет Байтұрсынұлы, Костанай, Казахстан, e-mail: kdnkdn@list.ru;

Салыкова О.С. - кандидат технических наук, ассоциированный профессор, Костанайский региональный университет им. Ахмет Байтұрсынұлы, Костанай, Казахстан, e-mail: solga0603@mail.ru;

Салыков Р.Б. - кандидат технических наук, ассоциированный профессор, Костанайский региональный университет им. Ахмет Байтұрсынұлы, Костанай, Казахстан, e-mail: salykovbulat@mail.ru;

Зарубин М.Ю. - кандидат технических наук, профессор, Костанайской инженерно-экономический университет им. М. Дулатова, Костанай, Казахстан, e-mail: zarubin_mu@mail.ru;

Кобжасаров Т.Ж. - PhD, Костанайский региональный университет им. Ахмет Байтұрсынұлы, Костанай, Казахстан, e-mail: kobzasarovt@gmail.com.

Information about the authors

Madin V.A. - master of technical sciences, Akhmet Baitursynuly Kostanay regional university, Kostanay, Kazakhstan, e-mail: vmadin@mail.ru;

Komarov D.N.- master of physics, Akhmet Baitursynuly Kostanay regional university, Kostanay, Kazakhstan, e-mail: kdnkdn@list.ru;

Salykova O.S. - candidate of technical sciences, associate professor, Akhmet Baitursynuly Kostanay regional university, Kostanay, Kazakhstan, e-mail: solga0603@mail.ru;

Salykov R.B. - candidate of technical sciences, associate professor, Akhmet Baitursynuly Kostanay regional university, Kostanay, Kazakhstan, e-mail: salykovbulat@mail.ru;

Zarubin M.Yu. - candidate of technical sciences, professor, Kostanay engineering and economics university named after M.Dulatov , Kostanay, Kazakhstan, e-mail: zarubin_mu@mail.ru;

Kobzhassarov T.Zh.- PhD, Akhmet Baitursynuly Kostanay regional university, Kostanay, Kazakhstan, e-mail: kobzasarovt@gmail.com.