

Раздел 2. «Информационно-коммуникационные технологии»

МРНТИ 06.81.23
УДК 004.032.26

Н.А. Шахов, Ж.И. Титова, С.В. Кан

*Карагандинский индустриальный университет, Темиртау, Казахстан
(e-mail: zh.titova@tttu.edu.kz)*

Применение нейронных сетей для диагностирования дефектов подшипников качения

Целью статьи является описание разработки алгоритма обнаружения дефектов подшипников качения с помощью нейронных сетей и оценка эффективности такого диагностирования. Рассматривается алгоритм обучения нейронной сети YOLOv8, который основан на архитектуре сверточных нейронных сетей и использует методы обучения с учителем. Эта модель принимает изображение в качестве входных данных и выдает оценки вероятности того, что на изображении присутствует определенный объект в режиме реального времени. В результате получен алгоритм обнаружения дефектов подшипников качения с помощью обученной нейронной сети, расчет оценки качества работы нейронных сетей, сформированы матрицы ошибок, получены результаты обработки нейронных сетей.

Ключевые слова: вибродиагностика, нейронная сеть, цифровые технологии, подшипник качения, алгоритм.

Введение

Надлежащее техническое обслуживание и своевременный ремонт способны существенно продлить срок службы промышленного оборудования. А также сократить затраты на его содержание (например, за счет снижения расходов на устранение последствий внеплановых остановов), повысить общую надежность работы предприятия и т. д.

Для крупных предприятий, особенно использующих сложное и дорогое оборудование, вопросы технического обслуживания и ремонтов (ТОиР) являются крайне важными. Затраты таких предприятий на ТОиР могут составлять более половины общих расходов на производство продукции.

При наличии на предприятии десятков тысяч единиц оборудования, подлежащего контролю состояния, обслуживанию, периодическим ремонтам и модернизации, эффективно выполнять ТОиР — не просто. Еще сложнее, если это оборудование «разбросано» по множеству территориально удаленных объектов. Облегчить управление ТОиР, повысить его эффективность призваны специализированные компьютерные программы.

Основная задача, стоящая перед этими системами - уменьшение затрат на обслуживание оборудования и повышение надежности его работы, что в конечном счете призвано снизить себестоимость производимой продукции и обеспечить стабильность работы предприятия.

Подшипник качения является ключевым компонентом роторных машин [1]. Ожидаемый отказ, такой как трещина в подшипнике, может привести к поломке всей машины, что приведет к огромным экономическим потерям. Что еще более важно, отказы подшипников качения составляют 30% и более от общего числа отказов вращающихся механизмов [2]. В результате крайне важно предотвратить отказы системы путем точного обнаружения ранних дефектов подшипников качения [3].

Методы и материалы

Нейронные сети предоставляют уникальные возможности для эффективной диагностики дефектов подшипников. Их способность обрабатывать большие объемы данных и выявлять сложные паттерны позволяет раннее обнаружение дефектов, что, в свою очередь, снижает риск аварий, увеличивает срок службы оборудования и оптимизирует производственные процессы. Такой подход не только повышает эффективность технического обслуживания, но и содействует общей безопасности

Раздел 2. «Информационно-коммуникационные технологии»

и экономии ресурсов предприятия.

Основные виды дефектов подшипников отражены в таблице 1.1. Дефектоскоп создает график отношения увеличения зазора в подшипнике (мм/с) к частоте вибраций dB и частоты вращения подшипника (Гц) [4].

Таблица 1.1 - Основные виды дефектов подшипников качения

№	Вид дефекта	Частоты основных признаков
1	Исправный подшипник	
2	Бой вала Дефект муфты	
3	Износ внутреннего кольца	
4	Износ наружного кольца	
5	Износ тел качения	
6	Неуравновешенность ротора (дисбаланс)	
7	Расцентровка	

Проанализировав различные виды диагностики дефектов подшипников [4], было решено задействовать для этих целей обученную сверточную сеть. Весь процесс диагностирования показан на рисунке 1.

Раздел 2. «Информационно-коммуникационные технологии»

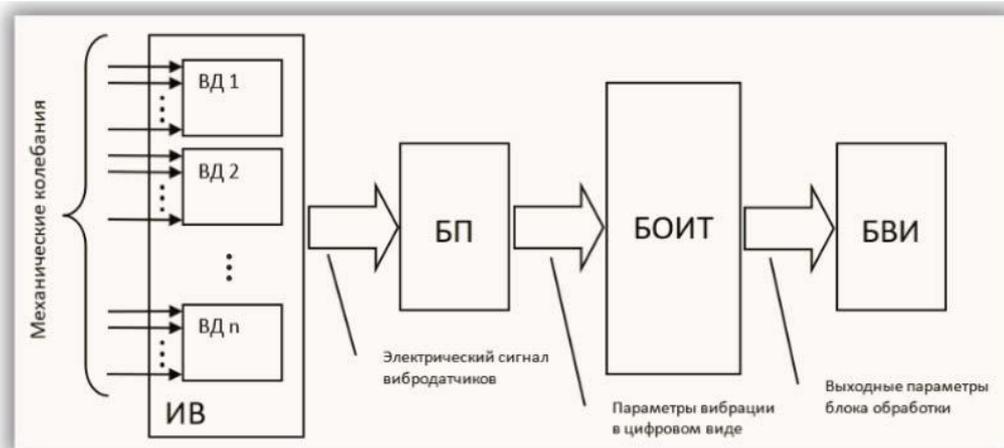


Рисунок 1. Процесс диагностирования дефектов подшипников

Блок преобразования (БП) – устройство или комплекс устройств, предназначенных для перевода исходного сигнала вибродатчиков в удобный для цифровой обработки формат. Это может быть персональный компьютер с установленной звуковой картой и необходимым программным обеспечением, или, в случае необходимости повышения точности, последовательность узконаправленных аналоговых устройств, реализующих функции аналог-цифрового преобразования, разложения в ряд Фурье и т.д.

Блок обработки информации о техническом состоянии (БОИТ) – блок, служащий для собственно определения технического состояния диагностируемого оборудования по заранее заданным правилам; главный объект автоматизации. В качестве этого блока может служить система ИИ: экспертная система нечёткого вывода, как было описано выше, или нейронная сеть, обученная на диагностику ряда неисправностей.

Блок вывода диагностической информации (БВИ) – устройство или ряд устройств для окончательного вывода сведений о неисправностях диагностируемого оборудования. В роли этого блока может выступать экран ПК, принтер для формирования отчётов, или электронный архив.

В рамках данной работы блок преобразования представлен дефектоскопом, блок обработки информации и блок вывода – персональным компьютером. Для определения вида неисправности предлагается применить искусственную нейронную сеть.

Для обучения нейронной сети было получено 65 изображений различных дефектов подшипников качения в качестве DataSet.

Эти данные представляют собой изображения с графиками, которые представляют собой увеличение зазора к частоте вращения или частота вибрации подшипника к частоте вращения.

При разметке DataSet учитывается, какие именно данные поступают на вход нейронной сети. Для этого при разметке изображений каждому изображению в DataSet присваивается свой класс в соответствии с классификацией дефектов подшипника.

Следующим этапом будет непосредственное обучение. Для этого создается сценарий, в который включаются библиотеки модели обучения, и где прописываются все настройки обучения сети.

После каждого цикла обучения нейронной сети появляются папки «trainX» (здесь X – это номер итерации обучения сети) и «predict». Папка «trainX» (обучение) содержит данные, которые используются для обучения нейронной сети YOLO. Обычно в ней хранятся изображения объектов, которые нужно обнаруживать, а также файлы разметки, указывающие на местоположение и класс этих объектов на изображениях. В процессе обучения нейронная сеть YOLO анализирует эти изображения и их разметку, чтобы научиться точно определять и классифицировать объекты на изображениях.

Папка «predict» (предсказание) используется для тестирования обученной модели YOLO на новых данных после завершения процесса обучения.

В нее обычно помещаются изображения или видео, на которых хочется провести обнаружение объектов. Затем обученная модель YOLO применяется к этим данным для предсказания местоположения и классов объектов.

Раздел 2. «Информационно-коммуникационные технологии»

Таким образом, папка «trainX» используется для обучения модели на известных данных, а папка «predict» - для тестирования модели на новых данных и получения предсказаний.

Содержимое папки «train» можно увидеть в таблице 2.

Таблица 2 – Данные для обучения нейронной сети

Файл	Предназначение
best.pt и last.pt	Это файлы, содержащие параметры обученной модели. "best.pt" обычно содержит параметры модели с лучшей производительностью на валидационном наборе данных, а "last.pt" содержит параметры модели, сохраненные после последней эпохи обучения.
args.yaml	Файл, в котором хранятся параметры обучения модели, такие как архитектура модели, размер пакета (batch size), количество эпох и т. д.
confusion_matrix.png и confusion_matrix_normalized.png	Диаграммы, отображающие матрицу ошибок для модели на валидационном наборе данных. Исходя из этой матрицы высчитываются значения метрик точности (precision), полноты (recall).
F1_curve.png, PR_curve.png, P_curve.png, R_curve.png	Графики, отображающие значения метрик точности (precision), полноты (recall) и F1-меры (F1-score) на различных пороговых значениях для модели на валидационном наборе данных (рис 2-4).
labels.jpg и labels_correlogram.jpg	Изображения, связанные с метками (классами) объектов, которые используются при обучении модели.
results.csv и results.png	Файл с результатами обучения, содержащий информацию о точности, потерях и других метриках модели на валидационном наборе данных. "results.png" может содержать визуализацию этих результатов (рис. 5).
train_batchX.jpg	Изображения, представляющие собой примеры пакетов данных для обучения.
val_batchX_labels.jpg	Представляет собой примеры пакетов данных для валидации. Содержит изображения из валидационного набора данных с наложенными метками (для ожидаемых классов)
val_batchX_pred.jpg	Представляет собой примеры пакетов данных для валидации. Содержит изображения из валидационного набора данных с предсказаниями модели.

Анализируя все эти данные выбирается лучший результат из всех серий (batch) и, если этот результат удовлетворяет конечного пользователя, то данная нейронная сеть считается обученной и может быть применена для диагностирования дефектов подшипников качения.

Результаты и обсуждение

Последующим этапом алгоритма является тестирование нейронной сети, выполняющей задачу обнаружения дефектов подшипника качения.

После того, как нейронная сеть обучена на обучающих данных, необходимо проверить ее работу на тестовых данных, которые не были использованы в процессе обучения. Для этого подается изображение на вход сети, и вычисляются выходы всех слоев. Последний слой сети выдает предсказанные ограничивающие прямоугольники и метки классов объектов на изображении. Формулы для расчета из [5]. Для оценки качества работы нейронной сети используются различные метрики, такие как:

Доля правильных ответов (ассигасу) - это доля правильно классифицированных объектов от общего числа объектов на изображении. Точность вычисляется по формуле (1):

Раздел 2. «Информационно-коммуникационные технологии»

$$accuracy = \frac{TP}{(TP+FP+FN)} \quad (1)$$

где

TP - истинно положительные (true positive), то есть объекты, которые были правильно обнаружены и классифицированы;

FP - ложно положительные (false positive), то есть объекты, которые были ошибочно обнаружены или классифицированы;

FN - ложно отрицательные (false negative), то есть объекты, которые не были обнаружены или классифицированы.

Полнота (recall) - это доля правильно обнаруженных объектов от общего числа реальных объектов на изображении. Полнота вычисляется по формуле (2):

$$recall = \frac{TP}{(TP+FN)} \quad (2)$$

Точность (precision) - это доля правильно обнаруженных объектов от общего числа предсказанных объектов на изображении. Точность вычисляется по формуле (3):

$$precision = \frac{TP}{(TP+FP)} \quad (3)$$

F-мера (F-measure) - это гармоническое среднее между точностью и полнотой, которое учитывает баланс между ними. F-мера вычисляется по формуле (4):

$$F - measure = 2 * precision * \frac{recall}{(precision+recall)} \quad (4)$$

Анализируя все эти данные выбирается лучший результат из всех серий (batch) и, если этот результат удовлетворяет конечного пользователя, то данная нейронная сеть считается обученной и может быть применена для диагностирования дефектов подшипников качения.

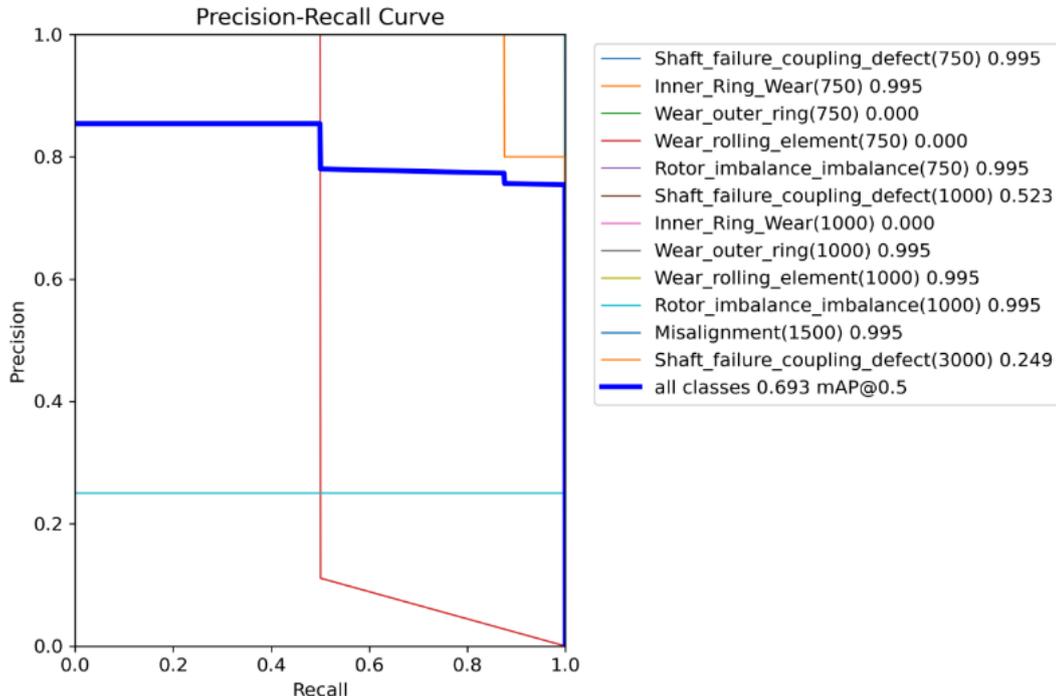


Рисунок 2. График отображающий значения метрики точности (precision) на различных пороговых значениях для модели на валидационном наборе данных

Из графика соотношения полноты и точности видно, что большинство классов дефектов определяются оптимально, однако некоторые классы - износ наружного кольца (Wear_outer_ring), износ элемента качения (Wear_rolling_element), износ внутреннего кольца (Inner_Ring_Wear) требуют

Раздел 2. «Информационно-коммуникационные технологии»

доработки.

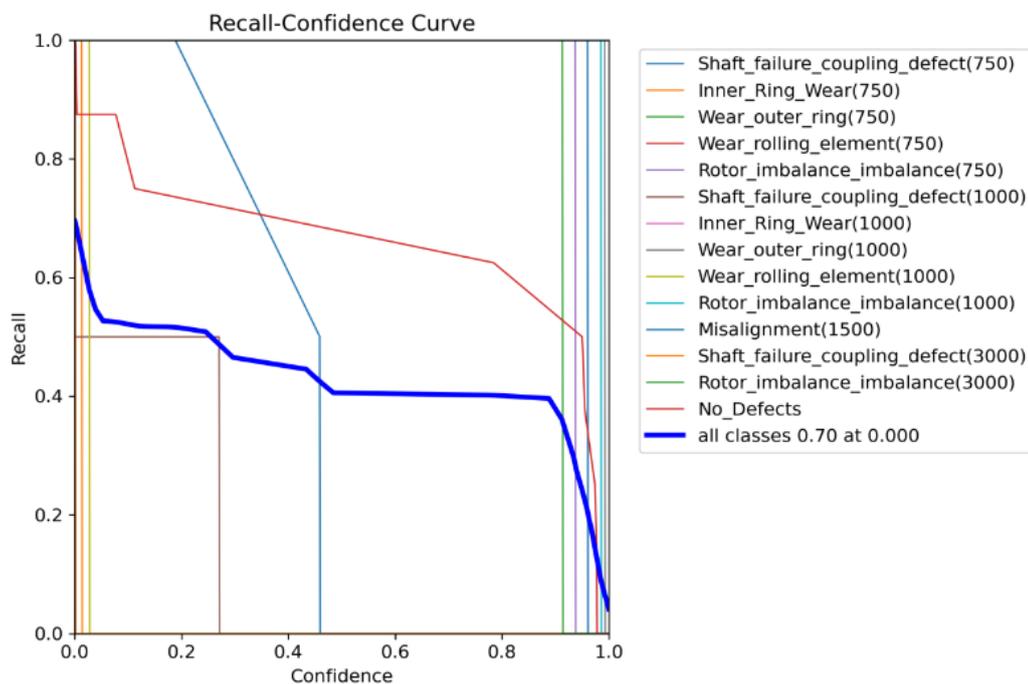


Рисунок 3. График отображающий значения метрики полноты (recall) на различных пороговых значениях для модели на валидационном наборе данных

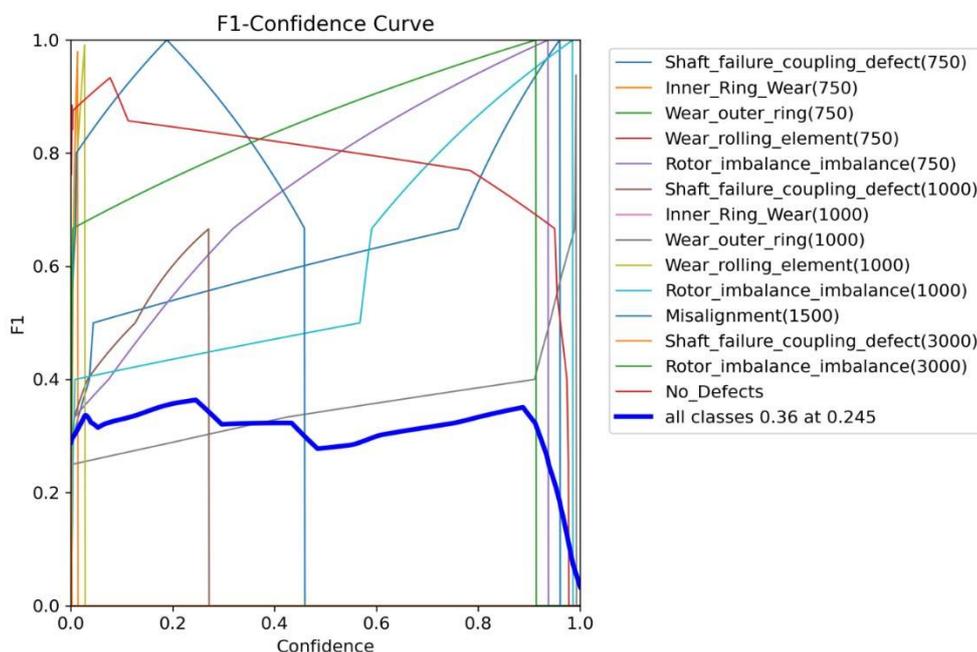


Рисунок 4. График отображающий значения метрики F1-меры (F1-score) на различных пороговых значениях для модели на валидационном наборе данных

В задаче обнаружения дефектов подшипников качения более важной метрикой является полнота, так как пропуск дефектов может привести к серьезным последствиям. Для нахождения оптимального баланса между полнотой и точностью используется F1-мера, которая объединяет обе метрики и отображается на соответствующем графике (рис.4).

Раздел 2. «Информационно-коммуникационные технологии»

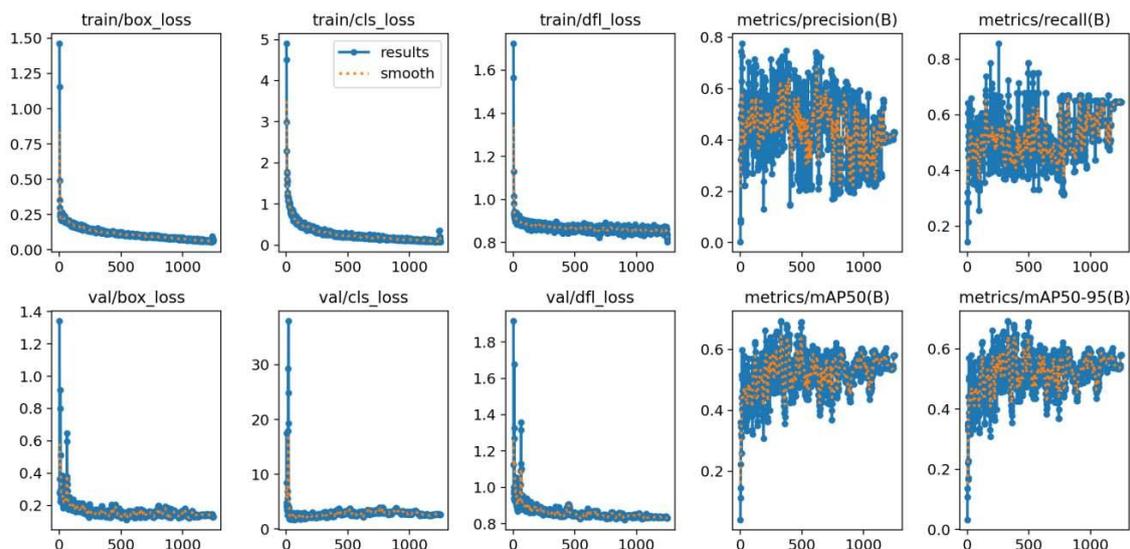


Рисунок 5. Результаты обучения

Результаты обучения, визуально представленные на рисунке, свидетельствуют о том, что нейронная сеть успешно адаптировалась к задаче выявления дефектов подшипников качения. На основании анализа графиков можно сделать вывод, что сеть демонстрирует необходимую точность и полноту в обнаружении дефектов, что подтверждает ее соответствие установленным требованиям. Достигнутый баланс между этими метриками указывает на готовность модели к практическому применению в системе диагностики.

Выводы

На основании проведенного исследования можно сделать вывод, что использование нейронных сетей для диагностики дефектов промышленного оборудования является эффективным и экономически целесообразным решением. Нейронные сети демонстрируют высокую точность и полноту в обнаружении дефектов, что позволяет своевременно выявлять потенциальные неисправности и снижать риски аварийных ситуаций. Кроме того, современные методы машинного обучения обеспечивают автоматизацию процесса диагностики, что значительно уменьшает затраты на ручной контроль и обслуживание оборудования.

Важным преимуществом нейронных сетей является их способность адаптироваться к новым данным и обучаться на разнообразных наборах характеристик оборудования, что повышает гибкость и универсальность этих технологий в различных промышленных отраслях. Снижение затрат на обслуживание, минимизация времени простоя и улучшение безопасности оборудования делает внедрение нейронных сетей рентабельным и перспективным направлением в сфере промышленной диагностики.

Список литературы

1. Zhixiong Li, Yu Jiang, Qiang Guo, et al. Multi-dimensional variational mode decomposition for bearing-crack detection in wind turbines with large driving-speed variations // *Renewable Energy*. 2018 . Vol.116 no. Part B P.55.
2. Xianguang Kong, Gang Mao, Qibin Wang et al. A multi-ensemble method based on deep auto-encoders for fault diagnosis of rolling bearings // *Measurement*. 2020 . Vol.151. no. 4. P.151.
3. Основные признаки и особенности развития дефектов [Электронный ресурс] : магазин подшипников : электрон. каталог. URL: <https://magazin-podshipnikov.ru/diagnostika-podshipnikov> (дата обращения: 20.12.2023).
4. Диагностика подшипников качения [Электронный ресурс] : ValTech : электрон. журн. 2017.

Раздел 2. «Информационно-коммуникационные технологии»

URL: <http://vibropoint.ru/diagnostika-podshipnikov-kachenia/> (дата обращения: 20.12.2023).

5. Метрики в задачах машинного обучения [Электронный ресурс] : HABR : электрон. журн. 2017. URL: <https://habr.com/ru/company/ods/blog/328372/> (дата обращения: 30.12.2023).

Н.А. Шахов, Ж.И. Титова, С.В. Кан

Домалау мойынтіректеріндегі ақауларды диагностикалау үшін нейрондық желілерді қолдану.

Мақаланың мақсаты-нейрондық желілер арқылы домалау мойынтіректерінің ақауларын анықтау алгоритмін әзірлеуді сипаттау және осындай диагностиканың тиімділігін бағалау. YOLOv8 нейрондық желіні оқыту алгоритмі қарастырылуда, ол конволюциялық нейрондық желілердің архитектурасына негізделген және мұғаліммен оқыту әдістерін қолданады. Бұл модель кескінді кіріс ретінде қабылдайды және суретте нақты уақыт режимінде белгілі бір объектінің болу ықтималдығын бағалайды. Нәтижесінде оқытылған нейрондық желінің көмегімен домалау мойынтіректерінің ақауларын анықтау алгоритмі алынды, нейрондық желілердің жұмыс сапасын бағалауды есептеу, қателік матрицалары құрылды, нейрондық желілерді өңдеу нәтижелері алынды.

Түйін сөздер: діріл диагностикасы, нейрондық желі, цифрлық технология, домалау мойынтірегі, алгоритм.

N.A. Shakhov, J.I. Titova, S.V. Kan

The use of neural networks to diagnose rolling bearing defects.

The purpose of the article is to describe the development of an algorithm for detecting rolling bearing defects using neural networks and to evaluate the effectiveness of such diagnostics. The YOLOv8 neural network learning algorithm is considered, which is based on the architecture of convolutional neural networks and uses teaching methods with a teacher. This model takes an image as input and provides estimates of the probability that a certain object is present in the image in real time. As a result, an algorithm for detecting rolling bearing defects using a trained neural network was obtained, the calculation of the evaluation of the quality of neural networks was performed, error matrices were formed, and the results of processing neural networks were obtained.

Keywords: vibration diagnostics, neural network, digital technologies, rolling bearing, algorithm.

List of literature

1. Zhixiong Li, Yu Jiang, Qiang Guo, et al. Multi-dimensional variational mode decomposition for bearing-crack detection in wind turbines with large driving-speed variations // Renewable Energy. 2018 . Vol. 116 no. Part B P. 55.

2. Xiangyang Kong, Sang Mao, Quan Wang et al. A multi-ensemble method based on deep auto-encoders for fault diagnosis of rolling bearings // Measurement. 2020 . Vol. 151. no. 4. P. 151.

3. The main signs and features of the development of defects [Electronic resource]: bearing store : electron. catalog. URL: <https://magazin-podshipnikov.ru/diagnostika-podshipnikov> (date of reference: 12/20/2023).

4. Diagnostics of rolling bearings [Electronic resource]: BalTech : electron. journal 2017. URL: <http://vibropoint.ru/diagnostika-podshipnikov-kachenia/> (accessed: 12/20/2023).

5. Metrics in the makings of machine learning [Electronic resource]: HABR : electron. journal 2017. URL: <https://habr.com/ru/company/ods/blog/328372/> (date of access: 12/30/2023).