

ИСПОЛЬЗОВАНИЕ АЛГОРИТМОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ПРОГНОЗИРОВАНИЯ ОТКАЗОВ ОБОРУДОВАНИЯ

Алгоритмы искусственного интеллекта все больше становятся востребованы при решении различных задач, возникающих на производстве. К таким задачам относится прогнозирование выхода из строя оборудования [1]. Оценка возможных отказов технологического оборудования помогает предприятиям снизить риски, связанные с неожиданными сбоями и простоями в текущей деятельности, а также оптимизировать графики технического обслуживания.

Перспективной областью для прогнозирования отказов оборудования является использование глубокого обучения – более узкого подмножества машинного обучения. Методы глубокого обучения позволяют повысить точность прогнозов. Используя многоуровневые нейронные сети и принципы глубокого обучения можно обрабатывать значительные объемы неструктурированных данных. Это относится к данным, которые не организованы заранее определенным образом или не имеют определенной модели или формы, таким как текст, изображения или звук.

Существует ряд подходов к прогнозированию и обнаружению отказов: аналитический, визуальный и с использованием моделирования [2].

Поиск потенциальных неисправностей аналитическим методом сводится к оценке и прогнозированию данных поступающих с измерительных средств, позволяя бороться с неисправностями на этапе их возникновения. Алгоритмы аналитического предсказания используют линейные и древовидные структуры данных для анализа и прогнозирования результатов в будущем. Основой для реализации таких алгоритмов может служить логистическая регрессия.

Визуальный анализ позволяет осуществить осмотр оборудования при помощи специальных оптических средств. Методы визуального надзора реализуются посредством алгоритмов для анализа данных, представленных иллюстрациями, графическими, визуальными образами. Для этих целей хорошо зарекомендовали себя системы аналитики построенные на базе свёрточных нейронных сетей.

Анализ на базе модели, подразумевает использование искусственного интеллекта не как инструмента предсказания показателей, а

как модели объекта в целом, основываясь на всей области имеющейся информации в целях получения долговременных прогнозов, и проблем, которые могут возникнуть в будущем [2]. При модельном анализе используют алгоритмы основанные на базе механизмов долговременной краткосрочной памяти, для прогнозирования показателей в будущем основываясь как на текущих значениях, так и на уже полученных ранее. Примером может быть вариант архитектуры рекуррентных нейронных сетей LSTM (Long Short-Term Memory).

Одним из современных инструментов для создания и обучения нейронных сетей является язык программирования Python. Популярность языка обусловлена наличием мощных библиотек, упрощающих реализацию архитектур нейронных сетей и алгоритмов глубокого обучения. При работе с алгоритмами искусственного интеллекта полезно задействовать такие библиотеки как NumPy, PyTorch и Pandas.

Библиотека NumPy является основной для анализа данных, машинного обучения и научных вычислений в среде Python. Этот пакет прикладных математических процедур значительно упрощает работу с векторами и матрицами.

PyTorch – библиотека для научных вычислений с широкой поддержкой алгоритмов машинного обучения. PyTorch позволяет создавать сложные нейронные сети с помощью контейнерного механизма. Компонент нейронной сети может представлять собой не только полносвязные или сверточные слои, но и функции активации или ошибки, а также готовые контейнеры.

Одним из самых популярных инструментов для работы с данными является библиотека Pandas. Pandas – это библиотека, которая хранит набор заранее подготовленных методов и функций, позволяющих использовать уже созданные и протестированные алгоритмы. Данная библиотека предназначена для анализа уже структурированных данных, она предварительно преобразовывает, обрабатывает и очищает данные. Для задачи прогнозирования отказа оборудования библиотека Pandas может использоваться в случае, если исходные данные уже структурированы, например в виде Excel таблицы, но данный формат данных не подходит для обучения модели.

Задачу прогнозирования отказа оборудования можно решить, взяв за основу логистическую регрессию. Логистическая регрессия – это алгоритм обучения классификации, который используется для прогнозирования вероятности возникновения некоторого события и выдаёт ответ в виде числа в промежутке от 0 до 1. Принцип работы логистической регрессии заключается в предсказании вероятности принадлежности наблюдения к определенному классу.

Для программной реализации логистической регрессии на языке программирования Python использованы библиотеки PyTorch со следующими модулями: nn (для построения нейронной сети) и utils (для работы с данными), библиотека matplotlib.pyplot для построения графика и библиотека torchvision с модулем transforms для работы с наборами данных и их преобразования [3].

В программе производилось обучение модели, определялись гиперпараметры модели и сам класс логистической регрессии LogisticRegression. В конструкторе данного класса `__init__()` создается слой нейронной сети с помощью `nn.Linear(input_size, num_classes)`. Также в классе присутствует метод `forward()`, с помощью которого определяется прямое распространение данных через модель [4].

Далее создаются объекты загрузчиков данных DataLoader для обучения и тестирования и создается экземпляр модели LogisticRegression, функция потерь CrossEntropyLoss() и оптимизатор SGD (стохастический градиентный спуск) с заданной скоростью обучения. После происходит обучение модели для каждой эпохи. После завершения обучения выводится финальная точность модели.

Второй способ решения задачи прогнозирования отказа оборудования – свёрточные нейронные сети (ConvNet/CNN). Каждая сеть состоит из нескольких слоев: входной слой, свёрточные слои, полносвязные слои и выходной слой.

Применяют операцию свёртки для извлечения локальных признаков из входных данных, характеризующих работу оборудования. Количество свёрточных слоев и размер фильтров подбираются экспериментально. Следующим шагом в рамках свёрточных слоев идет обычная активация на основании механизма функции активации ReLU для отбора положительных значений.

Реализованная программная модель представляет собой набор из точно таких же блоков, что и в случае логистической регрессии: два внешних слоя, внутренние слои и обратное распространение. Однако в свёрточной нейронной сети используется другая модель внутренних слоев и функции обратного распространения. Для реализации внутренних слоев используется функция `create_LeNet`. После нее идет функция тренировки с реализацией использования видеокарты, автоматического обратного распространения, и создание основных циклов нейронной сети. Так же используется стандартная функция прогнозирования, после прохождения обучения. Полученная программа выводит на выходе график, характеризующий отношение аккуратности (количества верных прогнозов к общему их количеству в эпохе) к количеству эпох.

В ходе разработки была реализована модель LSTM с применением базы данных, полученной на предприятии. LSTM или алгоритмы долговременной краткосрочной памяти – подвид линейных алгоритмов нейронных сетей, способный к анализу информации на основе не только имеющихся данных, но и на основе уже изученных образцов. Модель также находит между ними взаимосвязь с применением баз данных объектов. При реализации данной модели была задействована одна из первых реализаций модели LSTM, а именно, прямое прохождение со смещением относительно предыдущего результата на основании ковариационного счисления.

Данная реализация содержит две модели: первая модель – сверточная нейронная сеть с несколькими слоями Conv1D, MaxPooling1D и GlobalAveragePooling1D. На выходе используется слой Softmax для бинарной классификации; вторая модель – это та же архитектура CNN, но на выходе используется слой Dense с сигмоидной активацией для предсказания вероятности выхода из строя оборудования. С прохождением каждой эпохи точность увеличивается, а потери снижаются.

В процессе разработки одним из наиболее важных вопросов было решение проблемы вычислительных мощностей. В связи с этим был использован функционал, встроенный в библиотеку PyTorch, а именно возможность перенести вычисления с процессора на видеокарту. Для этого в программу обучения нейронной сети были добавлены метки, чтобы вычисления производились на видеокарте. Это накладывает целый ряд требований как к окружению, так и к операционной системе в целом: к специальной версии PyTorch требуется видеокарта от Nvidia для нейронных вычислений, также в операционной системе должен быть установлен набор специальных драйверов.

Использование различных моделей машинного обучения для прогнозирования отказов оборудования в реальной жизни является актуальной и перспективной разработкой. У каждой рассмотренной модели есть свои преимущества для применения их в реальной жизни. Так логистическая регрессия является простой и интерпретируемой моделью, хорошо подходит для бинарной классификации (отказ/нет отказа) и может эффективно работать с небольшими наборами данных и линейными зависимостями, но, к сожалению, ограничена в моделировании сложных нелинейных зависимостей, характерных для реальных систем. Сверточные нейронные сети способны извлекать сложные пространственные и временные закономерности из данных и эффективны в обработке многомерных данных, таких как изображения датчиков или временные ряды, но требуют больших объемов данных для обучения, что может быть проблемой в некоторых приложениях. На основе

результатов, полученных в случае применения модели LSTM заметна стабильность модели, что может свидетельствовать о большей устойчивости модели, а также снижении риска переобучения. Полученные результаты по сравнению с регрессионной моделью, характеризуют данную модель как более пригодную для практического использования.

Таким образом, комбинация различных моделей, в зависимости от особенностей данных и требований к точности, может обеспечить эффективное прогнозирование отказов оборудования в реальных условиях. Дальнейшие исследования и разработки в этой области могут привести к значительным улучшениям в области предиктивного обслуживания и повышения надежности критически важных систем.

ЛИТЕРАТУРА

1. Искусственный интеллект: современный подход, 4-е издание, том 3. Обучение, восприятие и действие: Пер. с англ. – СПб.: ООО «Диалектика», 2022. – 640 с.
2. Фостер Д. Генеративное глубокое обучение. Творческий потенциал нейронных сетей. – СПб.: Питер, 2021. – 336 с.
3. Python Developers, официальная страница для разработчиков: сайт. [Электронный ресурс] – URL: <https://developer.python.com> (дата обращения: 10.01.2025).
4. Официальная документация Python [Электронный ресурс] – URL: <https://docs.python.org/> (дата обращения: 11.01.2025).

УДК: 004.921, 004.946

А.В. Никитин, доц.; Н.Н. Решетникова, доц.
(ГУАП, г. Санкт-Петербург, Россия)

СЕНСОМОТОРНЫЙ И КОГНИТИВНЫЙ АНАЛИЗ ДЕЯТЕЛЬНОСТИ ЧЕЛОВЕКА КАК ОСНОВА СОЗДАНИЯ СИСТЕМ ЦИФРОВЫХ РЕАЛЬНОСТЕЙ

Авторы используют термин «цифровые реальности» (ЦР) как обобщающий для виртуальной и смешанной реальности (дополненная реальность и дополненная виртуальность), расширенной реальности, виртуальных миров и метавселенной.

Основная задача прикладных систем ЦР, ориентированных на помощь человеку в достижении поставленной цели – создать у него ощущение реальности попадания в мир, смоделированный на компьютере, который должен иметь не только реалистичную визуализацию, но и позволять взаимодействовать человеку с его объектами так же, как с