

УДК 004.852

А.С. Гончаров, А.О. Савельев, А.С. Писанкин, А.Ю. Чепкасов, Д.Н.К. Джаякоди

Подход к автоматическому прогнозированию состояния промышленных манипуляторов с применением методов машинного обучения

В связи с интенсивным развитием информационных технологий и наступлением 4-й промышленной революции количество роботизированных производств неуклонно растет. Также увеличивается объем производства и использования роботов. Одновременно с этим развивается направление по сопровождению и управлению цифровым производством. Робототехнические системы не способны полностью исключить человека из технологической цепочки, так как нуждаются в своевременном обслуживании и отработке персоналом внештатных ситуаций. Одним из способов по снижению рисков неожиданных поломок является прогностический подход к обслуживанию основных средств производства. Реализация данного подхода осуществляется с применением средств анализа данных. В настоящем исследовании приведены результаты применения методов машинного обучения для анализа данных промышленных роботов с целью прогнозирования потенциальных отказов.

Ключевые слова: промышленный робот, анализ данных, машинное обучение, предиктивная аналитика.
doi: 10.21293/1818-0442-2021-24-1-48-54

Отличительной чертой современности является существенное увеличение объемов информации, генерируемой различными системами, средами и сообществами. Не являются исключением и технически сложные производства. Оценка текущего состояния оборудования в составе сложных технологических комплексов и прогноз его работоспособности являются в настоящее время одной из приоритетных задач при построении промышленного интернета вещей [1, 2]. Вместе с этим развиваются подходы по организации информационной инфраструктуры для анализа данных крупных промышленных производств с использованием технологий облачных вычислений и беспроводной передачи данных [3, 4]. С развитием систем сбора данных (датчиков, протоколов передачи и агрегирования) становится возможным производство комплексного мониторинга и анализа исторических данных оборудования. Актуальной тенденцией технического обслуживания является прогностный подход, примером которого являются методы прогнозирования и управления здоровьем (Prognosis and Health Management), технического обслуживания на основе состояния (Condition-based Maintenance) и остаточный срок службы (Remaining Useful Life) [5–7]. Системы, реализующие метод прогнозирования и управления здоровьем, предназначены для прогнозирования потенциальных неисправностей и определения оставшегося срока службы оборудования [8]. Модели, реализующие оценку остаточного полезного ресурса оборудования, не только прогнозируют срок службы, но и обеспечивают доверительную границу предсказания. Принимая во внимание данный подход, инженеры могут планировать техническое обслуживание, оптимизировать операционную эффективность и избегать незапланированных простоев. Техническое обслуживание на основе состояния – это стратегия принятых решений по обслуживанию оборудования на основе данных о его фактическом

состоянии [9, 10]. Непрерывно генерируемые массивы данных промышленным оборудованием содержат потенциально полезные знания, которые можно использовать для улучшения и оптимизации производственных процессов [11, 12]. В общем виде процесс технического обслуживания на основе состояния представляет собой следующую последовательность работы с данными:

1. Сбор данных с оборудования программно-аппаратными средствами (датчики и системы мониторинга).
2. Агрегирование и подготовка данных в системах хранения.
3. Применение алгоритмов анализа данных с целью проведения процедуры оценки состояния оборудования, учитывая правила и нормы технического обслуживания.
4. Принятие решения о планировании мероприятий по обслуживанию оборудования с последующими оперативными действиями для устранения выявленных дефектов.
5. Обновление плана и норм по техническому обслуживанию оборудования.

Применение методов машинного обучения и искусственных нейронных сетей на этапе анализа данных для обучения математической модели прогнозирования технического состояния оборудования на основе исторических данных о работе позволяет перейти к прогностической модели технического обслуживания [13–15].

Цель

Настоящее исследование направлено на применение подходов интеллектуального анализа данных с целью прогнозирования работоспособности промышленных манипуляторов. В частных случаях прогнозирование направлено на выявление аномальных значений параметров при работе оборудования, классификации потенциальных неисправностей, обучение регрессионной модели для построе-

ния доверительного интервала измеряемых параметров. Подход анализа данных включает в себя: подготовку и первичную обработку данных, применение методов статистической обработки данных, создание и тестирование моделей машинного обучения, анализ результатов.

Цели исследования:

1. Создание и обучение модели для классификации нагрузки на промышленном манипуляторе – подход к решению задачи поиска аномальных значений, свидетельствующих о перегрузке.

2. Сравнительный анализ результатов работы моделей машинного обучения и искусственных нейронных сетей (ИНС) при решении задачи прогнозирования перегрева подвижных частей промышленного манипулятора в рамках предсказательного обслуживания.

Исследование проводилось на данных, собранных с приводов промышленных роботов (как манипуляторов, так и отдельных двигателей), которые выполняли однотипные рабочие операции в разных режимах работы (без нагрузки, с нагрузкой, с перегрузкой).

Задачи

Основные задачи в рамках настоящего исследования:

1. Сбор данных с приводов промышленных манипуляторов (испытательного стенда с приводами и отдельными роботами).

2. Разработка модуля управления выборками данных (для обучения и тестирования).

3. Разработка модуля управления моделями машинного обучения (создание, обучение, сохранение, тестирование).

4. Разработка модуля визуализации результатов работы моделей машинного обучения.

5. Обучение и тестирование моделей машинного обучения на данных о работе приводов промышленных манипуляторов.

Методы решения задач

Для обработки данных методами статистики использованы:

1. Нормализация данных (z-оценка) – для сравнения значений разброса данных между признаками.

2. Скользящее среднее – для формирования сглаженных временных рядов.

Для анализа данных методами машинного обучения использованы:

1. Методы регрессии: линейная модель, плотная модель, случайный лес, Гауссовский процесс – для выявления зависимости между признаками выборки с целью прогнозирования значения целевого параметра (например, температуры для решения задачи прогнозирования перегрева привода).

2. Методы искусственных нейронных сетей: сверточная, рекуррентная – для прогнозирования значения целевого параметра.

3. Методы классификации: Наивный Байес, опорных векторов, дерево решений – для классифи-

кации нагрузки на промышленном роботе при решении задачи выявления весовой перегрузки.

Разработка программного обеспечения

Основной бизнес-процесс, реализуемый приложением:

1. Загрузка исторических данных о работе промышленного робота, описывающих рабочий процесс в штатном и нештатном режиме.

2. Подготовка данных для обработки методами статистики, машинного обучения.

3. Обучение модели на выборке.

4. Тестирование и визуализация результатов.

В настоящее время разработано множество программных средств и библиотек, реализующих алгоритмические и математические методы. Для разработки использованы следующие программные средства:

1. MongoDB – нереляционная база данных для хранения выборок и моделей машинного обучения в виде JSON документов.

2. Django-Framework – фреймворк для создания веб-приложений на языке Python.

3. Pandas, Numpy – библиотеки обработки и подготовки данных на языке Python.

4. Scikit Learn, Keras – открытые библиотеки для создания моделей машинного обучения и нейронных сетей на языке Python.

5. Matplotlib, Plotly – библиотеки для визуализации данных на языке Python.

Результаты применения методов машинного обучения

Задача классификации нагрузки актуальна для промышленных манипуляторов, работающих с передвижением различного типа грузов. Штатные средства мониторинга и самодиагностики сигнализируют о перегрузке по весу только тогда, когда зафиксированы параметры, превосходящие определенный порог значений, заданный производителем как максимально допустимая нагрузка. Исходя из этого, оператор не сможет получить сигнализацию о том, что робот, который настроен на перемещение объектов определенного веса, манипулирует объектом, масса которого отклоняется от необходимой, но при этом значения параметров робота находятся в пределах допустимых значений. Для решения такой задачи применяются методы классификации, позволяющие определять текущую нагрузку на промышленном манипуляторе.

Исходный набор содержит данные по 25 опытам, каждый из которых реализует 5 экспериментов с определенным значением нагрузки. Каждый опыт состоит из набора данных для всех исполняемых команд рабочего цикла манипулятора, содержащего значения силы тока в электроприводе на каждой из четырех осей и метки соответствующей им нагрузки.

Для анализа были выбраны следующие поля набора данных:

1. Команда – это номер исполняемой операции, соответствующий номеру строки программы рабочего процесса.

2. Ось – подвижный элемент манипулятора (включает в себя силу тока на статоре, момент силы, скорость вращения).

3. Нагрузка – категория веса, которым оперирует манипулятор (варьируется от 0 до 4).

Для повышения точности из обучающей выборки исключены данные, соответствующие команде бездействия, использование которых в обучающей выборке нецелесообразно. Далее определен набор осей, чьи графики зависимостей силы тока от нагрузки приближены к виду монотонно возрастающей или убывающей функции (рис. 1).

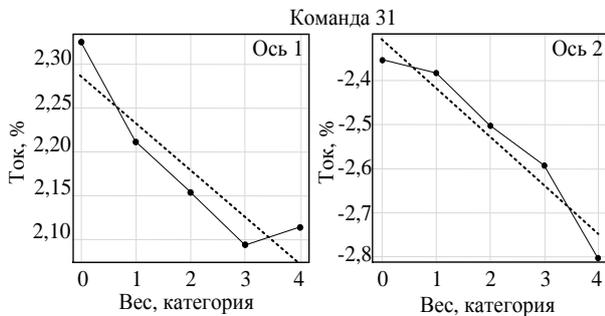


Рис. 1. Зависимость средних значений токов на осях № 1, 2 от нагрузки на манипуляторе; сплошная линия – средние значения тока при определенной нагрузке, пунктирная линия – монотонная функция

На основе проведенного анализа сформированы выборки:

1. Выборка 1 – для каждого веса формируется кортеж, значения которого – средние значения токов для осей, чьи графики зависимости приближены к виду монотонной функции.

2. Выборка 2 – замена значений токов, вносящих наибольшую погрешность, на значения аппроксимирующих прямых.

3. Выборка 3 – для каждого веса формируется кортеж, компонентами которого являются значения аппроксимирующих прямых.

4. Выборка 4 идентична выборке 1 за исключением данных, вносящих наибольшую погрешность.

Для решения задачи классификации нагрузки были отобраны три алгоритма, показавшие наилучший результат: Наивный Байес, дерево решений и метод опорных векторов. Входным признаком для обучения и тестирования моделей выбран ток на каждой из осей манипулятора. Выходным признаком является номер категории нагрузки. Общее количество строк данных в выборке 5 176 (примерно по 1 000 строк, описывающих цикл работы манипулятора с определенной категорией весовой нагрузки). Распределение данных на обучающую и тестовую выборки проводилось в соотношении 80:20 с использованием функции рандомизации. Эффективность используемых алгоритмов оценивается по двум параметрам: t – среднее время тестирования (в миллисекундах), P – точность (процент правильных ответов). Результаты работы алгоритмов машинного обучения представлены в табл. 1.

Таблица 1

Модель	Выборка 1		Выборка 2		Выборка 3	
	t , мс	P , %	t , мс	P , %	t , мс	P , %
Наивный Байес	1,09	88	1,03	84	1,35	92
Дерево решений	1,08	72	0,93	36	1,11	76
Метод опорных векторов	1,05	88	1,06	84	1,13	92

Достигнутый результат – определение веса с точностью 92%, определение нагрузки за полный рабочий цикл манипулятора. Из-за малого количества исходных данных и специфики решаемой задачи формирование обучающей выборки (значения, полученные линейной аппроксимацией данных) и тестовой выборки (усредненное значение по каждой команде) происходило на основе всех имеющихся данных, что вносит погрешность в полученный результат, однако достигнутая высокая точность, позволяет сделать вывод, что решение задачи определения нагрузки манипулятора по измеренным значениям силы тока на электроприводе возможна при использовании различных наборов данных для обучающей и тестовой выборок. Определить нагрузку на манипуляторе в произвольный момент времени не представляется возможным по двум причинам: диапазон изменения силы тока в ходе выполнения любой команды слишком велик (значения меняются произвольным образом), и в ходе исследования не была выявлена зависимость между нагрузкой и значением силы тока для некоторых команд рабочего цикла.

Апробация алгоритма прогнозирования неисправностей выполнена на примере задачи прогнозирования перегрева привода промышленного робота.

Исходный набор содержит данные, собранные с четырех промышленных манипуляторов, выполнявших определенный рабочий процесс на протяжении не менее 40 ч. Общее количество строк данных 188 323 (для одного манипулятора). Распределение данных на обучающую и тестовую выборки проводилось в соотношении 70:30 с использованием функции рандомизации. Для каждой оси манипулятора температура колеблется в определенном диапазоне, постепенно увеличиваясь в процессе выполнения рабочего процесса. С целью уменьшения погрешности была проведена аппроксимация временного ряда температуры.

На этапе подготовки данных для улучшения точности модели проведена операция по нормализации данных с применением z-оценки:

$$S = (x - \mu) / \sigma, \quad (1)$$

где x – значение, μ – среднее значение, σ – среднеквадратичное отклонение.

На рис. 2 изображен результат нормализации данных.

При обучении использовались следующие модели ИНС: линейная, плотная (линейная с несколь-

кими скрытыми слоями), сверточная ИНС, рекуррентная ИНС. Используемая функция активации: *relu*. Данная функция возвращает значение, переданное в функцию, если оно положительно, в противном случае возвращает значение ноль. На рис. 3 представлен результат тестирования модели.

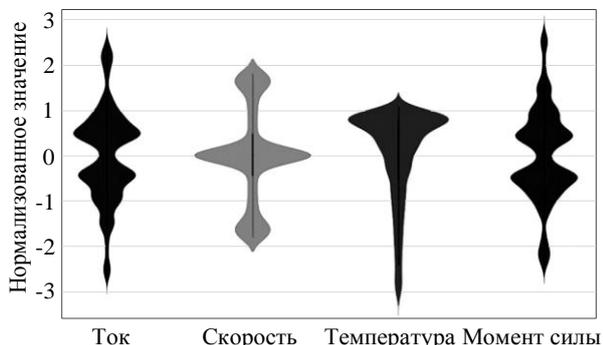


Рис. 2. Нормализованные данные для одной из выборок

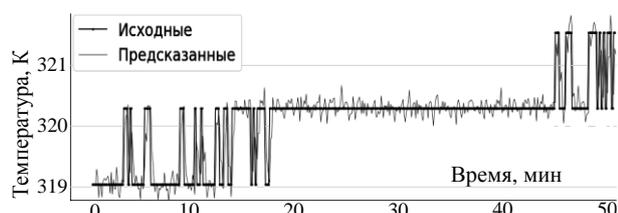


Рис. 3. Результат прогнозирования при использовании сверточной нейронной сети; толстая линия – исходные данные, тонкая линия – предсказанные данные

Эффективность выбранных алгоритмов машинного обучения для решения поставленной задачи определяется следующими параметрами: *t* – время обучения и *P* – относительная погрешность предсказаний температуры. В табл. 2 представлены результаты тестирования моделей ИНС.

Таблица 2

Результаты тестирования моделей

Модель	Метрики		
	<i>P</i> , %	<i>t</i> , с	Кол-во эпох
Линейная	2,4	24,27	17
Плотная	2,41	8,54	5
Сверточная ИНС	2,25	24,32	15
Рекуррентная ИНС	2,22	1184,9	20

Исходя из результатов тестирования, наибольшую точность показывает рекуррентная ИНС, однако сверточная ИНС показывает близкую точность прогнозирования при меньших временных затратах на обучение.

Прогнозирование значений температуры обеспечивается при помощи методов регрессии случайного леса (рис. 4) и Гауссовского процесса (рис. 5). Регрессионный анализ позволяет найти зависимость между зависимой величиной (в данном случае – температура привода) и независимыми переменными (скорость вращения, ток, момент силы) во временном ряду.

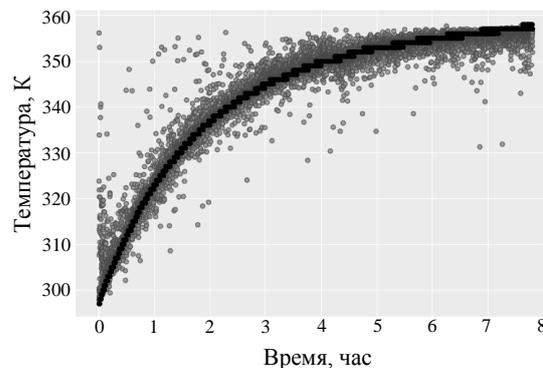


Рис. 4. Модель случайного леса (линия – измеренные данные; точки – прогнозируемые данные)

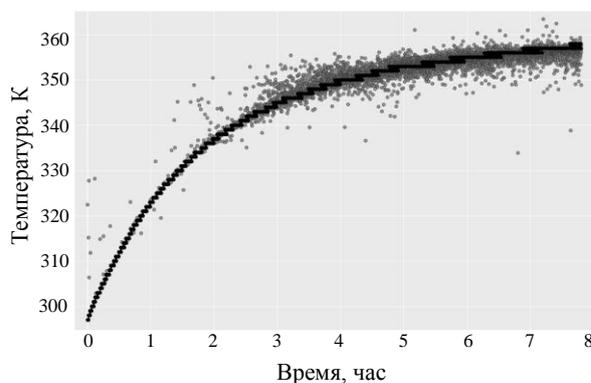


Рис. 5. Модель регрессора Гауссовского процесса (линия – измеренные данные; точки – прогнозируемые данные)

Эффективность выбранных алгоритмов машинного обучения для решения поставленной задачи определяется следующими параметрами: *t* – время обучения, MSE – среднеквадратичная ошибка, MAE – средняя абсолютная ошибка и оценка дисперсии регрессии (табл. 3).

Таблица 3

Результаты тестирования моделей

Модель	Метрики			
	<i>t</i> , с	MSE	MAE	Оценка дисперсии регрессии
Случайный лес	1	18,64	2,2	0,92
Гауссовский процесс	45	1,56	0,45	0,99

Исходя из результатов, можно сделать вывод, что модель регрессии Гауссовского процесса точнее модели регрессии случайного леса, но требует больше времени на обучение. Обученные модели, имеющие удовлетворительные результаты при тестировании (более 90% точности), могут быть использованы для анализа данных при реализации стратегии предсказательного обслуживания. В условиях непрерывной генерации данных производством указанные модели могут быть дообучены до требуемой точности при решении задач прогнозирования сбоев и отказов оборудования.

Заключение

В настоящем исследовании рассмотрен подход к прогнозированию состояния промышленного манипулятора с использованием методов ИНС и ма-

шинного обучения. Задача прогнозирования является актуальной и развитие технологий сбора и обработки данных обеспечивает переход к новой модели управления производством – управление и планирование бизнес-процессов предприятия на основе анализа данных (Data-driven decision management).

Несмотря на значительный прогресс в вопросах сбора и предварительной обработки данных, нет эффективного решения, обеспечивающего унификацию процесса управления различными типами промышленных манипуляторов, в том числе от разных производителей. Существующие на рынке решения по мониторингу и анализу данных собираются под конкретные типы роботов и производств, зачастую не совместимых с оборудованием другого производителя. Потенциальным решением является апробированный в рамках настоящей работы подход по анализу обобщенных данных о работе манипулятора (не привязанных к конкретной системе мониторинга) с использованием машинного обучения в качестве надстройки над системами сбора данных. Апробация подхода на тестовых данных при решении задачи определения значения целевого параметра – нагрузки – показала точность более 90% при применении моделей ИНС и машинного обучения.

Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-37-90113.

Литература

- Maintenance Analytics – The New Know in Maintenance / R. Karim, J. Westerberg, D. Galar, K. Uday // 3rd IFAC Workshop on Advanced Maintenance Engineering, Services and Technology AMEST. Biarritz, France. – 2016. – Vol. 49, No. 28. – P. 214–219.
- Him L.C. IoT-based Predictive Maintenance for Smart Manufacturing Systems / L.C. Him, Y.Y. Poh, L.W. Pheng // Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC). – Lanzhou, China, 2019. – P. 1942–1944.
- Ayad S. An IoT approach for a smart maintenance / S. Ayad, L.S. Terrissa, N. Zerhouni // 2018 International Conference on Advanced Systems and Electric Technologies (IC_ASET). – Hammamet, Tunisia, 2018. – P. 210–214.
- Chanv B. Structural health monitoring system using IOT and wireless technologies / B. Chanv, S. Bakhru, V. Mehta // 2017 International Conference on Intelligent Communication and Computational Techniques (ICCT). – Jaipur, India, 2017. – P. 151–157.
- Cachada A. Maintenance 4.0: Intelligent and Predictive Maintenance System Architecture / A. Cachada, J. Barbosa, L. Deusdado et al. // 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA). – Turin, Italy, 2018. – P. 139–146.
- Borgi T. Data analytics for predictive maintenance of industrial robots / T. Borgi, A. Hidri, B. Neef, M.S. Na-ceur // 2017 International Conference on Advanced Systems and Electric Technologies (IC_ASET). – Hammamet, Tunisia, 2017. – P. 412–417.
- Li Z. Prediction of Railcar Remaining Useful Life by Multiple Data Source Fusion / Z. Li, Q. He // IEEE Transactions on Intelligent Transportation Systems. – 2015. – Vol. 16, No. 4. – P. 2226–2235.
- Essential steps in prognostic health management / S. Das, R. Hall, S. Herzog, G. Harrison, M. Bodkin, L. Martin // 2011 IEEE Conference on Prognostics and Health Management. – Montreal, Canada, 2011. – P. 1–9.
- Zhang Y. Research on decision-making process of condition-based maintenance / Y. Zhang, S. Wang, X. Han // 2013 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (QR2MSE). – Chengdu, China, 2013. – P. 1437–1440.
- Rawat M. Condition based optimal maintenance strategy for multi-component system / M. Rawat, B.K. Lad. // 2013 IEEE International Conference on Industrial Engineering and Engineering Management. – Bangkok, China, 2013. – P. 1437–1441.
- Rahhal J.S. IOT Based Predictive Maintenance Using LSTM RNN Estimator / J.S. Rahhal, D. Abualnadi // 2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE). – Istanbul, Turkey, 2020. – P. 1–5.
- Kanawaday A. Machine learning for predictive maintenance of industrial machines using IoT sensor data / A. Kanawaday, A. Sane // 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS). – Beijing, China, 2017. – P. 87–90.
- Rastegari A. Maintenance decision making, supported by computerized maintenance management system / A. Rastegari, M. Mobin // 2016 Annual Reliability and Maintainability Symposium (RAMS). – Tucson, USA, 2016. – P. 1–8.
- Dsouza J. Preventive Maintenance for Fault Detection in Transfer Nodes using Machine Learning / J. Dsouza, S. Velan // 2019 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE). – Dubai, United Arab Emirates, 2019. – P. 401–404.
- Fariza V. Comparing Artificial Neural Network and Failure Distribution Methods for Maintenance Scheduling: A Case Study of Wooden Door Industry / V. Fariza, Z. Zulkarnain, I. Surjandari // 2018 5th International Conference on Information Science and Control Engineering (ICISCE). – Zhengzhou, China, 2018. – P. 161–165.

Гончаров Аркадий Сергеевич

Программист научно-образовательного центра «Автоматизация и информационные технологии» Инженерной школы информационных технологий и робототехники (ИШИТР) Национального исследовательского Томского политехнического университета (НИ ТПУ) Ленина пр-т, 30, г. Томск, Россия, 634050
Тел.: +7 (382-2) 70-17-77
Эл. почта: asg19@tpu.ru

Савельев Алексей Олегович

Кан. техн. наук, доцент отд. информационных технологий ИШИТР НИ ТПУ
Ленина пр-т, 30, г. Томск, Россия, 634050
Тел.: +7 (382-2) 70-17-77, вн. т. 44-31.
Эл. почта: sava@tpu.ru

Писанкин Андрей Сергеевич

Студент отд. информационных технологий ИШИТР НИ ТПУ
Ленина пр-т, 30, г. Томск, Россия, 634050
Тел.: +7 (382-2) 70-17-77
Эл. почта: asp66@tpu.ru

Чепкасов Артем Юрьевич

Студент отд. информационных технологий ИШИТР НИ ТПУ
Ленина пр-т, 30, г. Томск, Россия, 634050
Тел.: +7 (382-2) 70-17-77
Эл. почта: аус1@tpu.ru

Джаякоди Душанта Налин Кумара

Ph. D, профессор научно-образовательного центра
«Автоматизация и информационные технологии» ИШИТР
и робототехники НИ ТПУ
Ленина пр-т, 30, г. Томск, Россия, 634050
ORCID: 0000-0002-7004-2930
Тел.: +7 (382-2) 70-17-77, вн. т. 44-09
Эл. почта: nalin@tpu.ru

Goncharov A.S., Savelev A.O., Pisankin A.S.,
Chepkasov A.Y., Jayakody D.N.K.

Approach to an automatic prediction of the state of industrial manipulators using machine learning methods

Due to intensive development of information technologies and the onset of 4th industrial revolution the number of robotic industries is steadily growing. The volume of production and the use of robots is also increasing. At the same time, the support and the management of digital production is being rapidly developing. The robotic systems are incapable of completely excluding a person from the technological chain, since they need timely maintenance and personnel working out the emergency situations. One of the solutions to reduce the risk of unexpected breakdowns is a predictive approach to the maintenance. The implementation of this approach is carried out using data analysis tools. This study presents the results of applying machine learning methods to analyze data from industrial robots in order to predict potential failures.

Keywords: industrial robot, data analysis, machine learning, predictive analytics

doi: 10.21293/1818-0442-2021-24-1-48-54

References

1. Karim R., Westerberg J., Galar D., Uday K. [Maintenance Analytics – The New Know in Maintenance]. *3rd IFAC Workshop on Advanced Maintenance Engineering, Services and Technology AMEST*. Biarritz, France, 2016, vol. 49, no. 28, pp. 214–219.
2. Him L.C., Y.Y. Poh, L.W. Pheng. [IoT-based Predictive Maintenance for Smart Manufacturing]. *Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)*. Lanzhou, China, 2019, pp. 1942–1944.
3. Ayad S., Terrissa L.S., Zerhouni N. [An IoT approach for a smart]. *2018 International Conference on Advanced Systems and Electric Technologies (IC_ASET)*. Hammamet, Tunisia, 2018, pp. 210–214.
4. Chanv B., Bakhru S., Mehta V. [Structural health monitoring system using IOT and wireless]. *2017 International Conference on Intelligent Communication and Computational Techniques (ICCT)*. Jaipur, India, 2017, pp. 151–157.
5. Cachada A., Barbosa J., Deusdado L. et al. [Maintenance 4.0: Intelligent and Predictive Maintenance System]. *2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA)*. Turin, Italy, 2018, pp. 139–146.
6. Borgi T., Hidri A., Neef B, Naceur M.S. [Data analytics for predictive maintenance of industrial robots]. *2017 International Conference on Advanced Systems and Electric Technologies (IC_ASET)*. Hammamet, Tunisia, 2017, pp. 412–417.

7. Li Z., He Q. [Prediction of Railcar Remaining Useful Life by Multiple Data Source Fusion]. *IEEE Transactions on Intelligent Transportation Systems*. 2015, vol. 16, no. 4, pp. 2226–2235.

8. Das S., Hall R., Herzog S., Harrison G., Bodkin M., Martin L. [Essential steps in prognostic health management]. *2011 IEEE Conference on Prognostics and Health Management*. Montreal, Canada, 2011, pp. 1–9.

9. Zhang Y., Wang S., Han X. [Research on decision-making process of condition-based maintenance]. *2013 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering (QR2MSE)*. Chengdu, China, 2013, pp. 1437–1440.

10. Rawat M., Lad B.K. [Condition based optimal maintenance strategy for multi-component system]. *2013 IEEE International Conference on Industrial Engineering and Engineering Management*. Bangkok, China, 2013, pp. 1437–1441.

11. Rahhal J.S., Abualnadi D. [IOT Based Predictive Maintenance Using LSTM RNN Estimator]. *2020 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*. Istanbul, Turkey, 2020, pp. 1–5.

12. Kanawaday A., Sane A. [Machine learning for predictive maintenance of industrial machines using IoT sensor data]. *2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. Beijing, China, 2017, pp. 87–90.

13. Rastegari A., Mobin M. [Maintenance decision making, supported by computerized maintenance management system]. *2016 Annual Reliability and Maintainability Symposium (RAMS)*. Tucson, USA, 2016, pp. 1–8.

14. Dsouza J., Velan. S. [Preventive Maintenance for Fault Detection in Transfer Nodes using Machine Learning]. *2019 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*. Dubai, United Arab Emirates, 2019, pp. 401–404.

15. Fariza V., Zulkarnain Z, Surjandari I. [Comparing Artificial Neural Network and Failure Distribution Methods for Maintenance Scheduling: A Case Study of Wooden Door Industry]. *2018 5th International Conference on Information Science and Control Engineering (ICISCE)*. Zhengzhou, China, 2018, pp. 161–165.

Arkady S. Goncharov

Software Developer, School of Computer Science & Robotics, Scientific and Educational Center «Automation and Information Technologies», National Research Tomsk Polytechnic University (NI TPU) 30, Lenin pr., Tomsk, Russia, 634050
Phone: +7 (382-2) 70-17-77
Email: asg19@tpu.ru

Alexey O. Savelev

Candidate of Science in Engineering, Assistant Professor, School of Computer Science & Robotics, Department of Information Technology NI TPU 30, Lenin pr., Tomsk, Russia, 634050
Phone: +7 (382-2) 70-17-77, ext. 4431.
Email: sava@tpu.ru

Andrey S. Pisankin

Student, School of Computer Science & Robotics, Department of Information Technology NI TPU 30, Lenin pr., Tomsk, Russia, 634050
Phone: +7 (382-2) 70-17-77
Email: asp66@tpu.ru

Artem Y. Chepkasov

Student, School of Computer Science & Robotics,
Department of Information Technology NI TPU
30, Lenin pr., Tomsk, Russia, 634050
Phone: +7 (382-2) 70-17-77
Email: ayc1@tpu.ru

Dushantha Nalin K. Jayakody

PhD, School of Computer Science & Robotics,
Scientific and Educational Center «Automation and Infor-
mation Technologies» NI TPU
30, Lenin pr., Tomsk, Russia, 634050
ORCID: 0000-0002-7004-2930
Phone: +7 (382-2) 70-17-77, ext. 44-09
Email: nalin@tpu.ru