

Прогнозирование времени отказа оборудования технологического процесса с помощью искусственной нейронной сети

Имад Хамамех

Одной из целей интеллектуальной индустрии является снижение количества сбоев и времени, потраченного на устранение этих сбоев, что сокращает производственные издержки. Профилактическое обслуживание помогает решить эту проблему, но не всегда является эффективным способом. В контексте повышения эффективности технологического процесса основной вклад в эту работу может заключаться в том, чтобы предложить методику прогнозирования выполнимости технологического процесса. Обработка и преобразование собранных данных технологического процесса для обучения нейронной сети способны предсказать будущее состояние оборудования, указав, когда может произойти сбой, что позволяет точнее составлять график обслуживания. В результате лишних остановок оборудования для обслуживания становится меньше.

Для достижения этой цели была создана модель, имитирующая технологический процесс, вывод параметров и ожидаемое время возникновения отказа. Данные были использованы для обучения нейронной сети, а кроссвалидация – для тестирования. Также были применены другие методы обучения нейронной сети.

Введение

Для повышения качества и производительности производственного процесса контроль, мониторинг и техническое обслуживание оборудования производственной линии являются основными видами деятельности [1].

Датчики и исполнительные механизмы играют важную роль в работе различных компонентов технологического процесса, поэтому важно, чтобы они были в хорошем рабочем состоянии. Для достижения этой цели выполняются два вида обслуживания: запланированный и корректирующий. Плановое техническое обслуживание проводится регулярно; оборудование проверяется и при необходимости заменяется, чтобы избежать незапланированных остановок технологического процесса. Корректирующий ремонт проводится при возникновении сбоев; нерабочая деталь проверяется и при необходимости заменяется [2]. Несмотря на то что плановое техническое обслуживание более эффективно, оба вида повышают затраты из-за производственного сбоя. Для компенсации недостатков обоих видов обслуживания в промышленности стали широко использовать методы обслуживания на основе искусственного интеллекта. Эти методы позволяют спрогнозировать с большой точностью время сбоя в рабо-

те оборудования, что позволяет составить более эффективный график технического обслуживания. Этот вид обслуживания снижает количество остановок в производстве, а также ускоряет ремонт, поскольку может предсказать, на какой детали произойдет сбой [3].

Цели этой работы:

- использовать исторические данные или сгенерировать данные для обучения нейронной сети;
- использовать генетические алгоритмы для обучения нейронной сети с меньшим количеством данных и проверить качество обучения. Это важно, потому что в большинстве случаев невозможно получить нужное количество данных о технологическом процессе;
- использовать статистические методы для выявления важных факторов, которые влияют на технологический процесс.

Сопутствующие работы

Техническое обслуживание оборудования по его состоянию играет важную роль в сокращении лишнего обслуживания, времени простоя и снижении затрат.

Целью диагностики неисправностей является обнаружение происхождения сбоев и определение места сбоя. Это достигается выбором параметров и при-

нятым диапазоном значений этих параметров. В отличие от систем диагностики, системы прогнозирования отказов направлены на прогнозирование будущего поведения оборудования и определение возможных моментов отказа оборудования, помогая в принятии решений по вопросам технического обслуживания. *K. Verbert, B.D. Schutter* и *R.A. Babuska* предложили систему оптимизации технического обслуживания, используя многомодульный метод для прогнозирования износа оборудования [4]. *S. Ntalampiras* представил систему диагностики неисправностей, где для обнаружения неисправностей использовался безмодельный метод с использованием данных с физического уровня контролируемой системы [5]. *M. Yildirim, X.A. Sun, N.Z. Gebraeel* создали метод для эффективного планирования технического обслуживания на основе прогнозируемого состояния системы с использованием байесовских методов прогнозирования. Этот прогнозный анализ динамически оценивает распределение оставшегося срока службы электрических генераторов, позволяя оценить стоимость обслуживания и лучшее время для проведения технического обслуживания [6, 7].

Одна из задач, которую может выполнять искусственная нейронная сеть (ИНС), – это прогнозирование. В медицине ИНС использовались для прогнозирования риска смертности и заболеваемости. *Hao, Usama, Yang, Hossain* и *Ghoneim* представили новую мультимодальную рекуррентную нейронную сеть на основе данных (MD-RCNN) для прогнозирования риска заболеваний [10]. *F. Li, G. Ren* и *J. Lee* разработали инновационную структуру для многоэтапного прогнозирования скорости ветра с использованием рекурсивной нейронной сети на основе скорости ветра и интенсивности турбулентности [11].

ИНС в прогнозировании сбоев

ИНС широко используются в прогнозировании сбоев. *Orru, Zoccheddu, Sassu, Mattia, Cozza* и *Arena* представили простую и легко реализуемую модель

машинного обучения (ML) для раннего прогнозирования неисправностей центробежного насоса в нефтегазовой отрасли [5]. *Cheng H., Kong X., Chen G., Wang Q.* и *Wang R.* предложили метод для прогнозирования оставшегося срока полезного использования при множественных отказах системы, используя переносимую сверхточную нейронную сеть (TCNN) для изучения инвариантных функций домена [12]. *Atma Ram Sabu, Sanjay Kumar Palei* продемонстрировали подход к прогнозированию неисправностей в системе с использованием многослойного перцептрона (MLP) в ИНС, а также данных о причинах, симптомах и неисправностях за последние два года, записанных с помощью датчика, журнала и визуального осмотра [13].

Методы, применённые при разработке системы прогнозирования

В реальных системах сбор и обработка данных, используемых для машинного обучения, исторически должны выполняться относительно интересующей проблемы, например, сбоя оборудования. Определяя, когда конкретное оборудование вышло из строя, можно собрать предварительный набор данных, содержащий данные датчиков. Далее обрабатываются данные для получения подходящей выборки для обучения нейронной сети.

В этой работе представлены 3 вида данных для обучения нейронной сети: линейные данные, нелинейные данные, исключаяющие «или» данные с 15 параметрами и более 7000 показаний [14].

Использовались 3 вида оптимизации: метод роя частиц, алгоритм светлячков, стохастический градиентный спуск.

Цель данной работы – сравнить результаты алгоритмов и найти более подходящие алгоритмы для обучения нейронной сети при небольшом объёме данных, что позволяет применять методы прогнозирования в технологических процессах.

Метод роя частиц

Оптимизация роя частиц (PSO) – это метаэвристика, введённая Кеннеди и Эберхартом [15]. PSO поддерживает набор решений, которые итеративно обновляются для перемещения в пространстве поиска. Математические формулы применяются к скорости и положению каждой частицы. Скорость частицы определяет, насколько быстро частица перемещается в про-

странстве поиска, в то время как положение частицы представляет собой решение исследуемой проблемы. Расчёты на каждой итерации основаны на двух ранее найденных позициях. Скорость частицы вычисляется на каждой итерации по следующему уравнению:

$$v_i(t+1) = v_i(t) + c_1 r_1 (y(t) - x_i(t)) + c_2 r_2 (\hat{y}(t) - x_i(t)), \quad (2.1)$$

где t – текущая итерация, $x_i(t)$ – текущее положение частицы в измерении i , $v_i(t)$ – текущая скорость частицы в размерности i , $y_i(t)$ – лучшее положение текущей частицы в измерении i , $\hat{y}(t)$ – лучшая позиция в измерении i , ω – инерционный член, который применяет часть предыдущей скорости к следующей скорости, c_1 – когнитивный компонент, который влияет на эффект личного наилучшего найденного положения, c_2 – обобщённый компонент, который влияет на эффект глобального наилучшего найденного положения, а r_1 и r_2 – случайные значения в диапазоне [0, 1]. [19]

Алгоритм светлячка

Алгоритм светлячка (FA) был основан на образцах мигания и поведении светлячков [13]. FA использует следующие три идеализированных правила:

- светлячки однополюсы, поэтому одного светлячка привлекают другие светлячки независимо от их пола;
- привлекательность пропорциональна яркости, и оба параметра уменьшаются по мере увеличения расстояния. Таким образом, для любых двух мигающих светлячков более яркий будет двигаться к более яркому. Если нет более яркого светлячка, чем конкретный светлячок, он будет перемещаться случайным образом;
- яркость светлячка определяется ландшафтом целевой функции.

Поскольку привлекательность светлячка пропорциональна интенсивности света, наблюдаемого соседними светлячками, можно определить изменение привлекательности β с расстоянием r следующим образом:

$$\beta = \beta_0 e^{-\gamma r^2},$$

где β_0 – привлекательность при $r = 0$.

Движение светлячка i , притягивающегося к другому, более привлекательному (более яркому) светлячку j , определяется следующим образом:

$$x_i^{t+1} = x_i^t + \beta_0 e^{-\gamma r_{ij}^2} (x_j^t - x_i^t) + \alpha \epsilon_i^t, \quad (2.3)$$

где вторая часть обусловлена притяжением. Третья часть – это рандомизация, где α является параметром рандомизации, а ϵ_i^t – вектор случайных чисел, взя-

тых из распределения Гаусса или равномерного распределения в момент времени t . Если $\beta_0 = 0$, это становится простым случайным блужданием. С другой стороны, при $\gamma = 0$ FA сводится к варианту оптимизации роя частиц. Кроме того, рандомизацию можно легко распространить на другие распределения, такие как рейсы Леви [17].

Стохастический градиентный спуск

Это итерационный метод оптимизации целевой функции с подходящими свойствами гладкости. Его можно рассматривать как стохастическое приближение оптимизации градиентного спуска, поскольку оно заменяет фактический градиент (вычисленный из всего набора данных) его оценкой (вычисленной из случайно выбранного подмножества данных). Это снижает вычислительную нагрузку, особенно в задачах оптимизации большой размерности, обеспечивая более быстрые итерации для более низкой скорости сходимости [18, 19].

Результаты работы

В ходе исследования были созданы и обучены разные нейронные сети для разных задач (прогнозирование, линейные и нелинейные задачи) и получены следующие результаты.

Было выявлено, что метод роя частиц обучается быстрее (требует меньше итераций), чем остальные два метода в линейных задачах с маленьким пространством, но при использовании метода для обучения модуля прогнозирования результаты PSO были намного хуже, чем результаты FA и SGD. По результатам исследования PSO является плохим вариантом при обучении с большим количеством характеристик (входов) и маленькой обучающей выборкой.

FA дал лучшие результаты для таких задач, как исключаяющие «или». Разница увеличивается при большом количестве входов, при маленьком наборе данных FA не смог обучиться. Для задачи прогнозирования FA обучался быстрее и давал более точные результаты.

Заключение

Всё чаще в промышленности ищут более эффективные способы планирования обслуживания. Прогнозирование сбоев помогает создавать более эффективный график обслуживания оборудования, что снижает затраты.

В интеллектуальной индустрии более точное предсказывание наблю-

дается тогда, когда оборудование выходит из строя, что помогает принимать решения относительно технического обслуживания, которое необходимо выполнять, сводя к минимуму затраты и снижая рабочую нагрузку.

Основной результат работы состоит в предложении методики прогнозирования сбоев и планировании технического обслуживания с помощью нейронных сетей и выбора наилучшего метода обучения при различных видах и количестве данных. Предложенная методика также может стать целью будущих работ с учётом измерений реальных систем. Набор обучающих данных может быть построен на основе реальных измерений или смоделирован с помощью нелинейных оценок, таких как логарифмические или экспоненциальные.

Важно подчеркнуть, что исследования и разработка методов, которые помогают принимать решения в промышленности, имеют важное значение для повышения эффективности производства и снижения затрат.

Литература

1. *Amihai I.* An Industrial Case Study Using Vibration Data and Machine Learning to Predict Asset Health / I. Amihai // IEEE 20th Conference on Business Informatics (CBI). Vienna, Austria, 2018. P. 178–185.
2. *Plante T., Nejadpak A., & Yang C.X.* (2015). Faults detection and failures prediction using vibration analysis. IEEE AUTOTESTCON, (227–231). MD, USA: IEEE.
3. *Sampaio G.S., de Aguiar Vallim Filbo A.R., da Silva L.S., da Silva L.A.* Prediction of Motor Failure Time Using An Artificial Neural Network. 2019, 19(19), 4342.
4. *Verbert K.* A Multiple-Model Reliability Prediction Approach for Condition-Based Maintenance / K. Verbert, B.D. Schutter, R.A. Babuska // IEEE Transactions on Reliability. 2018. P. 1364–1376.
5. *Ntalampiras S.* Fault Diagnosis for Smart Grids in Pragmatic Conditions // IEEE Transactions on Smart Grid. 2016. № 9. P. 1964–1971.
6. *Yildirim M.* Sensor-Driven Condition-Based Generator Maintenance Scheduling. Part I: Maintenance Problem / M. Yildirim, X.A. Sun, N.Z. Gebraeel // Transactions on Power Systems. 2016. № 31. P. 4253–4262.
7. *Yildirim M.* Sensor-Driven Condition-Based Generator Maintenance Scheduling. Part II: Maintenance Problem / M. Yildirim, X.A. Sun, N.Z. Gebraeel // Transactions on Power Systems. 2016. № 31. P. 4263–4271.
8. *Machine Learning Approach Using MLP and SVM Algorithms for the Fault Prediction of a Centrifugal Pump in the Oil and Gas Industry // Sustainability.* 2020. № 12. P. 4766–4767.
9. *Daoud M.* A survey of neural network-based cancer prediction models from microarray data / M. Daoud, M. Mayo // Artificial Intelligence in Medicine. 2019. № 97. P. 204–214.
10. *Recurrent convolutional neural network based multimodal disease risk prediction // Future Generation Computer Systems.* 2018. № 92. P. 76–83.
11. *Li F.* Multi-step wind speed prediction based on turbulence intensity and hybrid deep neural networks / F. Li, G. Ren, J. Lee // Energy Conversion and Management. 2019. № 186. P. 306–322.
12. *Transferable convolutional neural network based remaining useful life prediction of bearing under multiple failure behaviors / H. Cheng, X. Kong, Q. Wang, R. Wang // Measurement.* 2021. № 168.
13. *Sabu A.R.* Fault prediction of drag system using artificial neural network for prevention of dragline failure / A.R. Sahu, S.K. Palei // Engineering Failure Analysis. 2020. № 113.
14. *www.kaggle.com: сообщество специалистов по науке о данных: сайт. // URL: https://www.kaggle.com/c/machine-failure-prediction/data (дата обращения: 10.02.2018).*
15. *Kennedy J.* Particle swarm optimization / J. Kennedy, R. Eberhart // Proceedings of IEEE International Conference on Neural Networks. IV. Perth, WA, Australia, 1995. P. 1942–1948.
16. *Yang X.S.* Firefly algorithms for multimodal optimization // Lecture Notes in Computer Science. 2009. № 5792. P. 169–178.
17. *Yang X.S.* Nature-Inspired Metaheuristic Algorithms. Luniver Press, 2010.
18. *Suvrit S., Stephen J.W., & Sebastian N.* Optimization for Machine Learning, 2012. Massachusetts: MIT Press.
19. *Хамамех Имад Нехадович, Алгоритмы PSO, FA и GD для прогнозирования сбоев промышленности // Современная наука: Актуальные проблемы теории и практики / Серия Естественные и Технические Науки – № 4, 2022. С. 130–136.*



НОВОСТИ МИРА


РОСТЕХ И БАУМАНКА СОЗДАДУТ ОБОРУДОВАНИЕ ДЛЯ ПРОМЫШЛЕННОЙ 3D-ПЕЧАТИ

Центр аддитивных технологий Госкорпорации Ростех и Московский центр лазерных технологий (МЦЛТ) – научно-инжиниринговый центр при МГТУ им. Баумана – заключили соглашение о сотрудничестве. Документ, направленный на создание оборудования для промышленной 3D-печати, подписали генеральный директор ЦАТ Владислав Кочкуров и генеральный директор МЦЛТ Александр Григорьянц.

В рамках проекта в Центре аддитивных технологий будет проведена апробация и опытная эксплуатация установки 3D-печати на базе технологии селективного лазерного плавления, разработанной специалистами МЦЛТ. Опытные образцы изделий, изготовленные на новом отече-

ственном оборудовании, пройдут испытания на соответствие техническим характеристикам, предъявляемым к авиационной продукции. Следующим шагом станет начало серийного производства оборудования для 3D-печати.

Основной потребитель продукции Центра аддитивных технологий – авиастроительная отрасль. Создание перспективной авиатехники, такой как самолеты Суперджет 100 или MC-21 с отечественными двигателями ПД-8 и ПД-14, немыслимо без технологий 3D-печати. Наша задача – обеспечить соответствующие возможности, предложить авиастроителям лучшие производственные решения. Совместная работа с Бауманкой направлена на создание нового поколения отечественного оборудования для этих целей, сказал генеральный директор ЦАТ Владислав Кочкуров.



Опытный образец 3D-принтера предназначен для выращивания изделий размером до 250×250×300 мм из металлических порошковых материалов: алюминиевых, бронзовых, титановых сплавов и нержавеющей стали.

rostec.ru

НОВОСТИ МИРА

**RDW TECHNOLOGY ЗАПУСКАЕТ
ПРОИЗВОДСТВО БАРЕБОН-
ПЛАТФОРМЫ НА МОЩНОСТЯХ GS
GROUP**

Российский вендор RDW Technology объявляет о старте серийного производства баребон-платформы под брендом RDW Computers на мощностях предприятий инновационного кластера «Технополис GS» (флагманский инвестиционный проект холдинга GS Group в г. Гусеве Калининградской области). Это единственная моноблочная платформа, выпуск которой локализован в Российской Федерации.

Интегрированный характер предприятий «Технополиса GS» позволил реализовать весь производственный процесс на одной площадке. Корпуса для баребонов изготавливают на заводе «Пранкор», собирают устройства на НПО «Цифровые Телевизионные Системы». Первая партия – 1500 штук.

Баребон – тот же моноблок, собранный по принципу «каркасной» системы и предназначенный для самостоятельной сборки пользователей. Баребон-платформа позволяет получить необходимое устройство, базирующееся на материнских платах наиболее распространённых форматов, и устанавливать процессоры требуемой производительности. Любому пользователю открываются неограниченные возможности в гибком подборе конфигурации устройства для решения требуемых задач.

На заводе «Пранкор» производится высококачественная технологическая оснастка различной конфигурации и сложности. Нарботанные компетенции позволили в короткие сроки организовать производство корпусов для нового устройства. Корпус баребон-моноблока RDW Computers состоит как из металлических, так и из пластиковых деталей. Детали из оцинкованной стали изготавливают методом холодной штамповки, детали из АБС-пластика – методом литья пластмасс под давлением.

На НПО «ЦТС» для производства баребон-платформ адаптировали линию финальной сборки. Процесс начинается с поверхностного монтажа электронных компонентов на плату. Затем происходит монтаж штыревых компонентов, после – пайка и сборка в корпус. Контроль качества осуществляется на всех этапах производства.

Баребон-платформа RDW Computers получила 23,8-дюймовый жидкокристаллический монитор с разрешением 1920×1080 точек, веб-камеру 5 МП, два динамика по 5 Вт, стереомикрофон, картридер, блок питания мощностью 250 Вт и безрамочный дизайн. Для повышения степени защиты информации модель снабжена считывателем радиочастотной идентификации (RFID) и сканером

отпечатка пальца. По мнению разработчиков, актуальные решения вызовут интерес к новой моноблочной платформе на рынке.

– Наша баребон-платформа сконструирована под наиболее распространённые форматы материнских плат, – рассказал о технических особенностях новинки коммерческий директор RDW Computers Роман Жданов. – В новом устройстве установлена плата собственного производства RDW-MB-B45M. На её базе сегодня собирается вся компьютерная техника бренда, находящаяся в реестре Минпромторга РФ. Материнка создана компанией в 2020 г. Это первая сертифицированная материнская плата в России на базе процессора AMD.

Новая баребон-платформа будет внесена в Единый реестр радиоэлектроники Минпромторга. Это позволит любому российскому производителю использовать её для повышения адвалорной доли в моноблоках собственного производства.

www.industry-hunter.com

**РАЗРАБОТЧИК РОССИЙСКИХ
ARM-ПРОЦЕССОРОВ СМЕНИЛ
ВЛАДЕЛЬЦА**

Основатель НПЦ «Элвис», разрабатывающего мобильные процессоры, в том числе «Скиф», вышел из капитала компании после трёх десятков лет работы. 68-летний Ярослав Петричкович продал 30% акций, и теперь контроль над «Элвисом», который переживает непростое время на фоне американских и британских санкций, перешёл к выходцу из АФК «Система» Михаилу Чёрному.

Производитель электроники гражданского назначения и разработчик российских ARM-процессоров научно-производственный центр (НПЦ) «Элвис» две недели назад сменил акционера, пишет «Коммерсант» со ссылкой на источники на рынке микроэлектроники и в правительстве.

После 30 лет работы из капитала компании вышел её основатель Ярослав Петричкович. Сотрудники компании рассказывают, что получили письмо, в котором сообщается, что 68-летний акционер покидает компанию, так как «перенёс тяжёлую болезнь и не может больше принимать активное участие в делах». С 2012 по 2020 гг. он занимал должность гендиректора предприятия.

Контроль над «Элвисом» получил глава правления компании, бывший исполнительный вице-президент АФК «Система» и член совета директоров «Башкирэнерго» Михаил Чёрный. Какую именно долю бизнеса он получил, источники издания не сообщили.

Представители рынка микроэлектроники уверены, что со сменой бенефициара прои-

зойдёт и корректировка направления развития компании. В то время как Петричкович был известен как «человек старой инженерной школы» с техническим складом ума; Чёрный больше преуспевал в коммерции и менеджменте. Это может помочь компании сменить приоритеты и начать работать с крупными партнёрами.

В 2021 г. стало известно, что «Элвис» создаст три мобильных процессора: для смартфонов («Скиф»), систем искусственного интеллекта и устройств Интернета вещей. Процессоры планировалось произвести на тайваньской фабрике TSMC.

Первые отладочные платы различной конфигурации со «Скифами» осенью 2021 г. получили «Инновационная внедренческая компания», с которой связан «Базальт СПО» – разработчик линейки ОС «Альт», «Открытая мобильная платформа» – разработчик российской мобильной ОС «Аврора», входящий в «Ростех» НИИ «Масштаб», ICL и «Байтэрг».

В конце 2021 г. «Элвис» также стал участником проекта «Россетей» для разработки программно-аппаратных комплексов робототехнических систем охраны. Компания также собиралась поставлять процессор «Скиф».

Согласно базе «Контур.фокус», выручка компании по итогам 2021 г. достигла 1,1 млрд руб., что на 55% ниже, чем по итогам 2020 г., когда она заработала 2,4 млрд руб. Чистая прибыль упала почти на 100% и составила 2,5 млн руб. вместо 237,1 млн руб. в 2020 г.

Вероятно, не лучшим для бизнеса окажется и 2022 г., в том числе из-за пакета санкций США, который был введён на фоне геополитического кризиса на Украине 4 марта 2022 г. Жертвой санкций «Элвис» оказался наряду с другими отечественными чипмейкерами: «Байкал электроникс», МЦСТ, НТЦ «Модуль» и пр. Согласно ограничениям, иностранные контрагенты теперь обязаны согласовывать с бюро промышленности и безопасности (BIS) Минторга США все поставки российским компаниям. Речь идёт о любой продукции, произведённой по американским технологиям. Американский регулятор намерен действовать в рамках «политики отказа».

Великобритания в отношении «Элвиса» ввела санкции 5 мая 2022 г. Они означают заморозку активов организаций и ограничения на оказание технологических услуг, среди которых запрет на использование в новых разработках архитектуры британской компании ARM и возможные ограничения на производство на фабриках по всему миру текущих моделей процессоров. В довершение всего производство российских процессоров было остановлено на заводах тайваньской TSMC.

www.russianelectronics.ru