

2. Бальшин М. Ю. Порошковое металловедение. М.: Metallurgizdat, 1948. 332 с.
3. Верхотуров А.Д., Муха И.М. Технология электроискрового легирования металлических поверхностей. Киев: Техника, 1982. 181 с.
4. Кипарисов С.С., Либенсон Г.А. Порошковая металлургия. М.: Металлургия, 1991. 432 с.
5. Лазаренко Б.Р. Электроискровая обработка токопроводящих материалов. М.: АН СССР, 1959. 184 с.
6. Петров Ю.Н. Электроискровое легирование металлических поверхностей. Кишинев, 1985. 196 с.
7. Самсонов Г.В., Верхотуров А.Д., Бовкун Г.А., Сычев В.С. Электроискровое легирование металлических поверхностей. Киев: Наукова думка, 1976. 219 с.
8. Сафронов Г.В. Электроискровое легирование металлических поверхностей. Киев: Наукова думка, 1979. 119 с.
9. Федорченко И.М. Основы порошковой металлургии. Киев: Издат. Академии наук Украинской ССР, 1963. 420 с.
10. Цукерман С.А. Порошковая металлургия. М.: Издат. Академия наук СССР, 1958. 158 с.
11. Энциклопедия по машиностроению XXL, 2015. URL: <http://mash-xxl.info/>

References

1. Andreevskii R.A. *Poroshkovoe materialovedenie* [Powder materials]. Moscow: Metallurgiya, 1991. 205 p.

2. Bal'shin M.Iu. *Poroshkovoe metallovedenie* [Powder metallography]. Moscow: Metallurgiya, 1948. 332 p.
3. Verhoturov A.D., Muha I.M. *Tehnologiya elektroiskrovogo legirovaniia metallicheskih poverkhnostei* [Technology of electrosark alloying metal surfaces]. Kiev: Tehnika, 1982. 181 p.
4. Kiparisov S.S., Libenson G.A. *Poroshkovaia metallurgiya* [Powder materials]. Moscow: Metallurgiya, 1991. 432 p.
5. Lazarenko B.R. *Elektroiskrovaia obrabotka tokoprovodiashchih materialov* [Electric disintegration of conductive materials]. Moscow: AN SSSR, 1959. 184 p.
6. Petrov Iu.N. *Elektroiskrovoe legirovanie metallicheskih poverkhnostei* [Electric spark alloying of metal surfaces]. Kishinev, 1985. 196 p.
7. Samsonov G.V., Verhoturov A.D., Bovkun G.A., Sychev B.C. *Elektroiskrovoe legirovanie metallicheskih poverkhnostey* [Electric spark alloying of metal surfaces]. Kiev: Naukova dumka, 1976. 219 p.
8. Safronov G.V. *Elektroiskrovoe legirovanie metallicheskih poverkhnostey* [Electric spark alloying of metal surfaces]. Kiev: Naukova dumka, 1979. 119 p.
9. Fedorchenko I.M. *Osnovy poroshkovoi metallurgii* [Fundamentals of powder metallurgy]. Kiev: Izdat. Akademii nauk Ukrainskoi SSR, 1963. 420 p.
10. Tsukerman S.A. *Poroshkovaia metallurgiya* [Powder materials]. Moscow: Akademiia nauk SSSR, 1958. 158 p.
11. *Enciklopediia po mashinostroeniiu XXL* [Encyclopedia of mechanical engineering], 2015. Available at: <http://mash-xxl.info/>

УДК 004.021

Н.И. Шаханов, И.А. Варфоломеев, Е.В. Еришов, О.В. Юдина
Череповецкий государственный университет

ПРОГНОЗИРОВАНИЕ ОТКАЗОВ ОБОРУДОВАНИЯ В УСЛОВИЯХ МАЛОГО КОЛИЧЕСТВА ПОЛОМОК

Предложена модель прогнозирования отказов оборудования на основе алгоритма машинного обучения Random Forest. Рассмотрены ключевые этапы построения и настройки модели. Модель включает в себя несколько подмоделей, прогнозирующих отказ оборудования, используя фактические и прогнозируемые показания с датчиков. График разности в показаниях фактического и прогнозного значения сигналов в последующий промежуток времени используется для выявления отказов и аномалий. Обучение модели проводится на нормальных данных, а настройка модели на данных о предыдущих поломках.

Прогнозирование отказов, машинное обучение, Random Forest, дерево решений, модель.

Model predicting equipment failures based on machine learning algorithm Random Forest is suggested. The key stages of construction and configuration of the model are considered. The model includes several sub-models predicting equipment failure, using the actual and forecasted readings from the sensors. Schedule difference in the readings of actual and forecasted values of the signals in the subsequent period of time is used to detect failures and anomalies. Model's training is conducted on normal data, setting thresholds on data with breakdowns.

Forecasting failures, machine learning, Random Forest, decision tree, model.

Введение

Финансовые потери от ошибочных решений о прекращении эксплуатации промышленного оборудования или, наоборот, о необоснованном продлении его ресурса измеряются миллионами рублей. Это делает задачу оценки оборудования и прогнозирования его отказов чрезвычайно актуальной для обеспечения планирования его загрузки и ремонтов, безопасной эксплуатации. Наличие достаточно точного

прогноза отказов сможет обеспечить высокую надежность, безопасность и экономическую эффективность эксплуатации промышленных объектов [1].

Основной путь повышения эксплуатационной надежности состоит в том, чтобы прогнозировать неисправности устройств. На основании прогноза неисправностей устройств предсказывают возможности выхода оборудования из строя, что позволяет выявлять неисправные устройства для их последую-

щего ремонта или снятия с эксплуатации. Как результат, минимизируется возможность проявления неисправностей и отказов оборудования.

Эксплуатация любой детали машины предполагает воздействие на нее большого количества различных факторов, которые вызывают изменения в техническом состоянии, что со временем приводит к отказу. Существенной особенностью этих факторов является их случайный (стохастический) характер. К факторам, оказывающим наиболее существенное влияние на скорость изменения технического состояния детали, относятся: технологические нагрузки, прочностные характеристики материала детали, геометрические размеры. Кроме них, необходимо выделить такие факторы, как: соблюдение условий технологического процесса, качество технического обслуживания, качество ремонта, вибрация, температура и др. Случайный характер рассмотренных факторов приводит к непредсказуемому изменению технического состояния устройств, их узлов, механизмов, следовательно, и времени работы до отказа [5].

Для решения задачи прогнозирования сроков отказов различными исследователями было предложено множество моделей, отличающихся набором входных данных, методами ее анализа и формой представления результатов:

- метод прогнозирования времени отказа деталей с использованием законов распределения их ресурсов, полученных из статистики ремонтов;

- метод, проведенный Гребником В.М. и Цапко В.К., позволяет использовать значения напряжений, возникающих в детали, измеренные с помощью специальных приборов, и характеристики детали для прогнозирования ресурса;

- метод прогнозирования отказов на основе данных диагностики, с использованием номограмм.

Каждый из этих методов предполагает использование собственной процедуры прогнозирования, что определяется видом и характером исходной информации. Каждый из этих методов выполняется в два этапа. На первом этапе определяются параметры прогнозирования, а на втором – осуществляется процедура определения времени работы оборудования до отказа. Таким образом, точность прогнозирования каждого из таких методов напрямую зависит от выбора параметров.

Основная часть

Прогнозирование отказов

Современное оборудование снабжено необходимым количеством датчиков и приборов контроля, позволяющих отслеживать большое количество параметров его работы. При прогнозировании отказов необходимо выбрать наиболее информативные из них. Для решения этой задачи могут быть использованы методы машинного обучения (МО) [6]. Прогнозирование отказов оборудования на основе методов МО в последнее время становится все более актуальной задачей, решаемой в таких областях, как: машиностроительное производство, транспортные системы, промышленность, поскольку применяемые методы более эффективны по сравнению с методами,

основанными на нечеткой логике, статистических методах и т.п. Для этого достаточно провести анализ рынка и посмотреть на предложения в области предиктивного обслуживания оборудования таких известных компаний, как SAS, IBM [2], SAP [7] и др. Однако предложенные подходы к построению прогнозных моделей ориентированы на обучение на прецедентах, что в ряде случаев не может быть применено на практике. Например, в ситуациях, когда поломки происходят достаточно редко или нет достаточно большой статистики. Поэтому применение методов МО для повышения качества прогнозов отказов оборудования с целью снижения аварийности, издержек является актуальным.

Процедура МО требует достаточного количества данных, соответствующих описываемому режиму работы, так как сбор данных, соответствующих тем или иным отказам требует наблюдения в течение длительного времени эксплуатации, и этих данных может быть критически мало, например, для нового оборудования. Поэтому обучение осуществляется на данных, которые соответствуют нормальному режиму функционирования объекта исследования (т.е. в то время, когда не было поломок и других аномалий). Тем самым модель учится прогнозировать, каким должен быть сигнал при нормальном режиме работы. В том случае, если в определенный момент времени фактическое значение сигнала отличается от прогнозируемого «нормального» значения сигнала, фиксируется аномальное поведение и сигнализируется о возможной поломке.

Рассмотрим ключевые этапы построения модели прогнозирования при данном подходе. Предлагается следующая модель, состоящая из этапов сбора параметров, обучения модели и прогнозирования. На первом этапе определяется перечень всех параметров, которые собираются с узлов агрегата. К таким параметрам (для большинства агрегатов, использующих электродвигатели, подшипники скольжения, систему смазки и т.п.) можно отнести: температуру подшипников, температуру масла, температуру воды, температуру обмоток статора, давление масла, вибрацию подшипника, виброскорость, ток двигателя и т.д. Положительный эффект от избыточности собираемых параметров заключается в том, что модель прогнозирования сможет учитывать такие факторы, которые могут показаться незначительными с точки зрения влияния на отказ. При этом важным является то, что обучающая выборка состоит только из данных, в которых нет отказов и аномалий.

Рассмотрим настройку и работу алгоритма на примере прогнозирования отказов электродвигателя, когда в качестве входных параметров используются ток двигателя, осевое смещение вала и осевое смещение двигателя. Данные с трех датчиков собраны в базе данных в процессе его эксплуатации за одну неделю (рис. 1).

Для формирования входных параметров и для дальнейшего обучения алгоритма отбрасываем те промежутки времени, на которых данные были неполными, были зафиксированы отказы оборудования или оборудование работало в аномальном режиме. На рис. 1 с 5 июля с 7 часов утра до 6 июля 1 часа

ночи, данные отбрасываются, так как на первом интервале времени они неполные, и на втором интервале оборудование работало с аномалиями. Также известно, что 9 июля была зафиксирована неисправность оборудования, следовательно, эти данные так же отбрасываются. Таким образом, с 3 июля по 5 июля и с 6 июля по 9 июля данные можно использовать для следующего этапа.

На втором этапе проводится обучение модели прогнозирования. В качестве алгоритма МО был выбран Random Forest. Этот алгоритм основан на построении большого числа деревьев решений, каждое из которых строится по набору, получаемому из исходной обучающей выборки с возвращением. Особенностью является то, что при построении каждого дерева на каждой стадии ветвления вершины используется фиксированное число случайно отбираемых параметров обучающей выборки и строится полное (без усечения) дерево. Оценка регрессии осуществляется с помощью усреднения оценок регрессии всех деревьев. Задача регрессий сводится к задаче классификации. Диапазон допустимых значений делится на отрезки. Один отрезок – один класс. Чем более разнообразны классификаторы ансамбля, тем выше вероятность корректности прогнозирования [4].

К достоинствам использования Random Forest для прогнозирования отказов можно отнести: выявление латентных связей у нескольких сигналов, когда на значение одного сигнала оказывает воздействие другой или другие сигналы; в процессе обучения алгоритм умеет выявлять значимые параметры, которые в первую очередь влияют на прогноз, и откидывать менее значимые параметры.

На этапе обучения строятся 3 модели. Каждая модель прогнозирует значения одного из параметров в следующий момент времени по предыдущим значениям всех параметров. Входные параметры для

всех моделей одинаковые – это значения всех трех сигналов за предыдущие 20 мин. с шагом в 1 мин. (всего 60 значений). Первая модель прогнозирует значение силы тока, вторая модель прогнозирует осевое смещение вала в следующий момент времени, и третья модель прогнозирует осевое смещение двигателя (рис. 2).

Далее выборка разделяется на две части – обучающую (75 %) и тестовую (25 %). Обучив данный алгоритм, получаем 3 модели, которые будем использовать для прогнозирования.

Каждая из моделей представляет собой 100 бинарных деревьев решений. Пример бинарного дерева для определения тока представлен на рис. 3.

На третьем этапе, после того, как все модели построены, необходимо определить алгоритм, согласно которому система будет определять возникновение аномалии по трем сигналам. Для этого каждую из 3 моделей запускают для прогнозирования дальнейшей нормальной работы оборудования. В качестве стартовых данных для прогнозирования используют последние значения по датчикам за 20 мин. работы агрегата. После получения следующего прогнозируемого значения сигнала для модели входные параметры при первой минуте работы оборудования отбрасываются, и спрогнозированные параметры за 21 мин. добавляются к входным. Таким образом, каждую модель прогоняют для прогнозирования значений параметров в течение следующих двух часов работы (по 120 значений для каждого из трех параметров) и вычисляют отклонения этих прогнозных сигналов с фактическими за тот же период. В результате получаем данные об отклонениях прогнозных и фактического сигнала в каждый момент времени. Чтобы определить возможность поломки оборудования в этот период времени, необходимо установить порог по максимальному возможному отклонению




Рис. 1. График показаний с датчиков за неделю эксплуатации




Рис. 2. Структура модели прогнозирования
 I – сила тока, А; $OC_{\text{вала}}$ – осевое смещение вала, мм/с; $OC_{\text{двиг}}$ – осевое смещение двигателя, мм/с




Рис. 3. Дерево принятия решений для величины силы тока I
 $OC_{\text{вала}}$ – осевое смещение вала, мм/с; $OC_{\text{двиг}}$ – осевое смещение двигателя, мм/с; I – сила тока, А

прогнозного сигнала от фактического. Практика показывает, что превышение порога должно иметь место в течение некоторого времени. При этом порог необходимо установить так, чтобы не допустить ложных срабатываний и минимизировать пропуск реальных поломок. Если имеются данные о поломках, в таком случае порог устанавливается на основе этих данных, также выбирается интервал времени, в течение которого определяется превышение порога. В данном случае, если для последних 20 значений в 95 % и более случаев было зафиксировано превышение порога, информируется о том, что оборудование неисправно.

На рис. 4 показаны графики фактического и прогнозного сигнала за предыдущие 50 мин. работы оборудования для модели, прогнозирующей осевое смещение. По графику отклонений видно, что более

95 % значений превысили установленный порог в 0,18 мм/с для осевого смещения вала за период времени с 6:55 до 7:15. Также виден рост отклонений в показаниях, который свидетельствует о том, что в дальнейшем возникнет поломка оборудования. С учетом того, что разность в показаниях сигналов в 7:15 стала превышать более, чем в 6 раз, модель сообщила о критическом состоянии, при котором дальнейшая работа оборудования приведет к поломке. Через 11 мин. дальнейшей работы оборудования произошла поломка, связанная с утечкой смазки из подшипника, при этом до 6:55 оборудование еще работало в нормальном режиме. Таким образом, модель сообщила о неисправности в 6:15 при зафиксированном осевом смещении в 2,5 мм/с, отказ оборудования был зафиксирован в 7:26 при осевом смещении в 2,9 мм/с.




Рис. 4. Выявление аномалии

Литература

Заключение

Таким образом, для предотвращения отказов сложного промышленного оборудования в статье предложен новый подход к прогнозированию поломок на основе алгоритмов МО. Данный подход позволяет максимально использовать информацию о работе агрегата, собираемую с его узлов в нормальном режиме работы. Модель включает в себя несколько подмоделей, прогнозирующих отказ оборудования, каждая из которых использует фактические и прогнозные показания с датчиков. Для прогнозирования сигнала используется алгоритм МО Random Forest. Для обучения используются только данные при нормальном режиме работы агрегата, в отличие от аналогичных подходов, при которых для обучения необходимы данные до и во время неисправности оборудования. Задача алгоритма МО – спрогнозировать нормальный сигнал для каждого датчика, используя значения сигналов в за предыдущий промежуток времени. Для выявления отказов и для диагностики узлов агрегата [3] модель анализирует разность в показаниях фактического и прогнозного нормального сигналов в последующий промежуток времени. При обучении на прецедентах модель выявляет паттерны в показаниях датчиков, которые были зафиксированы в моменты времени, предшествующие отказам оборудования. При совпадении этих паттернов с фактическим сигналом фиксируется потенциальный отказ. При подходе прогнозирования отказов оборудования в условиях малого количества поломок, предложенном в работе, данные об отказах используются только при настройке модели для минимизации ложных оповещений об отказе оборудования и минимизации пропусков реальных поломок.

Данная модель была апробирована, алгоритм проверяется в работе в действующей ИТ-системе предприятия. Из-за возникшей сложности интеграции модели в эту систему было разработано программное обеспечение, позволяющее транслировать построенные модели Random Forest на языке R в язык C# и SQL: «Генератор программного кода моделей Random Forest». Программное обеспечение было зарегистрировано в Роспатент, свидетельство № 2016616932 от 22.06.2016.

1. Антонов А.В. Проблемы поддержания работоспособности оборудования АСУ ТП АЭС с реакторами ВВЭР. Вероятностные методы прогнозирования ресурса на стадии эксплуатации, разработка и внедрение программных средств. ИАТЭ, Обнинск, Россия. И.Ф. Моисеев ВНИИА-ЭС, Москва, Россия.

2. Виктор М. Прогнозная аналитика для эффективного использования оборудования. 2016. URL: http://filearchive.cnews.ru/files/reviews/2016_03_29/2_Maltsev.pdf

3. Виноградова Л.Н., Данилицкий С.В. Диагностика опор скольжения агрегатов металлургического производства методами неразрушающего контроля Череповецкие научные чтения – 2013. Ч. 3. С. 39–41.

4. Чистяков С.П. Случайные леса: обзор // Труды Карельского научного центра РАН. 2013. № 2. С. 117–136.

5. Шибаков В.Г., Исавнин А.Г., Малныч А.А. Модели для определения сроков отказа узлов и деталей кузнечно-штамповочных машин // Камская государственная инженерно-экономическая академия. Набережные Челны, 2009. URL: http://www.rusnauka.com/25_NPM_2009/Tecnic/51364.doc.htm

6. Alestra S., Brand C., Burnaev E., Erofeev P., Papanov A., Bordry C., Silveira-Freixo C. Rare event anticipation and degradation trending for aircraft predictive maintenance // 11th World Congress on Computational Mechanics, WCCM 2014, 5th European Conference on Computational Mechanics, ECCM 2014 and 6th European Conference on Computational Fluid Dynamics, ECFD 2014 11, 2014. С. 6571–6582.

7. Oliver M. Predictive Maintenance & Service (PdMS) – Outline and Value Proposition. 2014. URL: <https://blogs.saphana.com/wp-content/uploads/2014/11/Predictive-Maintenance-Service-Outline-Value-Proposition.pdf>

References

1. Antonov A.V. Problemy podderzhaniia rabotosposobnosti oborudovaniia ASU TP AJeS s reaktorami VVJeR [The maintenance problems of the equipment of automated process control system of nuclear power plants with reactors VVER]. *Veroiatnostnye metody prognozirovaniia resursa na stadii ekspluatatsii, razrabotka i vnedrenie programmykh sredstv*. [Probabilistic methods of resource forecasting of the operational phase, the development and implementation of software]. Obninsk State Technical University of Atomic Energy, Obninsk, Russia. Moses I.F. All-Russian Scientific Research Institute of Nuclear Power Operations, ARSRINPO, Moscow, Russia.

2. Victor M. *Prognoznaya analitika dl'a ehffektivnogo ispol'zovaniia oborudovaniia* [Predictive analytics for effective

use of the equipment], 2016. Available at: http://filearchive.cnews.ru/files/reviews/2016_03_29/2_Maltsev.pdf

3. Vinogradova L.N., Danilitsky S.V. Diagnostika opor skol'zheniia agregatov metallurgicheskogo proizvodstva metodami nerazrushaiushhego kontrol'a [Diagnostics sliding bearings metallurgical production units NDT methods]. *Cherepovets Scientific Readings – 2013*, part 3, pp. 39–41.

4. Chistyakov S.P. *Sluchainye lesa: obzor* [Random forests: a review]. Transactions of Karelian Research Centre of RAS, 2013, no. 2, pp. 117–136.

5. Shibakov V.G., Isavnin A.G., Malnych A.A. *Modeli dl'a opredeleniia srokov otkaza uzlov i detalei kuznechno-shtampovochnykh mashin* [Models to determine the timing of failure units and components of forging and stamping ma-

chines]. Kama State Engineering and Economic Academy, Naberezhnye Chelny, Russia, 2009. Available at: http://www.rusnauka.com/25_NPM_2009/Tecnic/51364.doc.htm

6. Alestra S., Brand C., Burnaev E., Erofeev P., Papanov A., Bordry C., Silveira-Freixo C. Rare event anticipation and degradation trending for aircraft predictive maintenance. *11th World Congress on Computational Mechanics, WCCM 2014, 5th European Conference on Computational Mechanics, ECCM 2014 and 6th European Conference on Computational Fluid Dynamics, ECFD 2014* 11, 2014, pp. 6571–6582.

7. Oliver M. Predictive Maintenance & Service (PdMS) – Outline and Value Proposition. 2014. Available at: <https://blogs.saphana.com/wp-content/uploads/2014/11/Predictive-Maintenance-Service-Outline-Value-Proposition.pdf>