

13. Ereemeev A.P., Muntyan E.R. Razrabotka ontologii na osnove grafov s mnozhestvennymi i raznotipnymi svyaziyami [Development of an ontology based on graphs with multiple and different types of edges], *Iskusstvennyy intellekt i prinyatie resheniy* [Artificial intelligence and decision making], 2021, No 3, pp. 3.18.
14. Zyablova E.R. Ispol'zovanie grafovyykh podkhodov dlya resheniya zadachi prognozirovaniya v oblasti formirovaniya kar'ernykh traektoriy [The use of graph approaches to solve the problem of forecasting in the field of career trajectories formation], *Tr. XII Mezhdunarodnoy nauchno-prakticheskoy konferentsii «Integrirovannye modeli i myagkie vychisleniya v iskusstvennom intellekte»* [Proceedings of the XII International Scientific and Practical Conference "Integrated models and soft computing in artificial intelligence"], in 2 vol. Vol. 1. Smolensk: Universum, 2024, pp. 150-158.
15. Yarushkina N.G. Osnovy teorii nechetkikh i gibridnykh sistem [Fundamentals of the theory of fuzzy and hybrid systems], Moskva: Finansy i statistika, 2004, 320 p.
16. Muntyan E.R., Kolodenkova A.E. Ispol'zovanie parsera social'nykh setey dlya modelirovaniya organizatsionnykh sistem [Using a social network parser for modeling of organizing systems], *Informatizatsiya i svyaz'* [Informatization and communication], 2022, No 2, pp. 30-34.
17. Muntyan E.R. Formirovanie tsifrovogo portreta sub"ekta na osnove parsinga seti dlya postroeniya kar'ernoy traektorii [Formation of a digital portrait of the subject based on network parsing to build a career trajectory], *Informatizatsiya i svyaz'* [Informatization and communication], 2023, No 3, pp. 36-41.
18. Muntyan E.R. Razrabotka algoritma proporsional'nogo razdeleniya GH-grafa dlya formirovaniya zon vliyaniya ob"ektov v slozhnykh tekhnicheskikh sistemakh [Developing a GH-graph proportional separation algorithm to form of object influence zones in complex technical systems], *Programmnye produkty i sistemy* [Software & Systems], 2023, vol. 36(3), pp. 378-387.
19. Ipatov Yu.A., Kalyagin I.V. Analiz dinamicheskikh kharakteristik tselevykh grupp sotsial'nykh setey [Analysis of dynamic characteristics of target groups of social networks], *Kibernetika i programmirovaniye* [Cybernetics and programming], 2019, No. 1, pp. 37-50.
20. Muntyan E.R. Podkhody k dogeneratsii grafa reprezentativnoy vyborki dlya modelirovaniya vzaimodeystviya sotsial'nykh grupp [Approaches to the graph increasing of representative sample for modeling the interaction of social groups], *Informatizatsiya i svyaz'* [Informatization and communication], 2018, No 4, pp. 18-24.
21. Zyablova E.R., Voloshchuk V.I. Organizatsiya poiska soobshchestv v sotsial'nykh setyakh s ispol'zovaniem GH-grafov [Organization of community search in social networks using GH graphs], *Gibridnye i sinergeticheskie intellektual'nye sistemy: Sb. statej po materialam nauchnoy VII Vserossiyskoy Pospelovskoy konferentsii* [Hybrid and synergetic intelligent systems. collection of articles based on the materials of the scientific VII All-Russian Pospelov conference], Kaliningrad, St. Petersburg, 2024, pp. 294-302.
22. Zyablova E.R. Modifikatsiya algoritma poiska krachayshikh putey GH-grafa dlya analiza slozhnykh tekhnicheskikh sistem [Modification of the algorithm for finding shortest paths for the formation of influence zones of objects in complex technical systems on GH-graphs], *Programmnye produkty i sistemy* [Software & Systems], 2024, vol. 37, No 3, pp. 354-363.

Зяблова Евгения Ростиславна – Южный федеральный университет; e-mail: zero32f@mail.ru; г. Таганрог, Россия; тел.: 88634371656; кафедра вычислительной техники; к.т.н.; доцент.

Zyablova Evgenia Rostislavna – Southern Federal University; e-mail: zero32f@mail.ru; Taganrog, Russia; phone: +78634371608; the Department of Computer Science; cand. of eng. sc.; associate professor.

УДК 517.977.1

DOI 10.18522/2311-3103-2024-6-142-155

Ю.А. Кораблёв

ПРОГНОЗИРОВАНИЕ НЕИСПРАВНОСТЕЙ В ТЕХНИЧЕСКИХ СИСТЕМАХ НА ОСНОВЕ МОДЕЛИ СХОДСТВА ОСТАВШЕГОСЯ ПОЛЕЗНОГО СРОКА СЛУЖБЫ

В этой статье показано, как построить полный рабочий процесс оценки оставшегося полезного срока службы (Retaining Useful Life - RUL), включая этапы предварительной обработки, выбора трендовых функций, построения индикатора работоспособности путем объединения датчиков, обучения оценщиков сходства RUL и проверки эффективности прогнозирования. Тестирование метода проводилось в демонстрационной программе MATLAB, реализующей данный

метод прогнозирования возникновения неисправностей в технических системах (<https://www.mathworks.com/help/predmaint/ug/similarity-based-remaining-useful-life-estimation.html>) на основе данных из "PHM08 Challenge Data Set", NASA Ames Prognostics Data Repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames Research Center, Moffett Field, CA. Метод ориентирован на использование обоснованных технических характеристик оцениваемого оборудования, достаточно полно освещенных в справочной литературе. Поэтому хорошие результаты метод дает при оценке оборудования, условия эксплуатации которого, близки к среднестатистическим. В статье используется Predictive Maintenance Toolbox™ системы MATLAB, который включает в себя несколько специализированных моделей, разработанных для вычисления RUL из различных типов измеренных системных данных. Эти модели полезны, когда у вас есть исторические данные и информация, такие как: – истории работы до отказа машин, похожих на ту, которую необходимо диагностировать. Исторические данные для каждого члена ансамбля данных подгоняются под модель идентичной структуры; – известное пороговое значение некоторого индикатора состояния, указывающего на отказ; – данные о том, сколько времени или сколько использования потребовалось для выхода из строя похожих машин (срок службы). Модели оценки RUL предоставляют методы для обучения модели с использованием исторических данных и их использования для выполнения прогнозирования оставшегося срока службы. Термин срок службы здесь относится к сроку службы машины, определяемому с точки зрения любой величины, используемой для измерения срока службы системы. Аналогично, эволюция времени может означать эволюцию значения с использованием, пройденным расстоянием, количеством циклов или другой величиной, которая описывает срок службы. Общий рабочий процесс для использования моделей оценки RUL: – создать и настроить соответствующий объект модели; – обучите модель оценки с использованием имеющихся исторических данных; – используя тестовые данные того же типа, что и имеющиеся исторические данные, оцените RUL тестового компонента. Также можно использовать тестовые данные рекурсивно для обновления модели по мере поступления новых данных, т.е. отслеживать эволюцию прогноза RUL по мере поступления новых данных.

Неисправности; диагностика состояния технической системы; прогнозирование возникновения неисправностей; оставшийся полезный срок службы; индикатор работоспособности; оценок сходства RUL.

J.A. Korablev

PREDICTION OF FAULTS IN TECHNICAL SYSTEMS BASED ON THE SIMILARITY MODEL OF THE REMAINING USEFUL LIFE


This paper demonstrates how to construct a complete Remaining Useful Life (RUL) estimation workflow, including the steps of preprocessing, selecting trend features, constructing a health indicator by fusing sensors, training RUL similarity estimators, and verifying the prediction performance. The method was tested in a MATLAB demo program implementing this method for predicting the occurrence of faults in technical systems (<https://www.mathworks.com/help/predmaint/ug/similarity-based-remaining-useful-life-estimation.html>) based on data from the "PHM08 Challenge Data Set", NASA Ames Prognostics Data Repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames Research Center, Moffett Field, CA. The method is focused on the use of reasonable technical characteristics of the equipment being estimated, which are sufficiently covered in the reference literature. Therefore, the method gives good results when assessing equipment whose operating conditions are close to the statistical average. This paper uses the Predictive Maintenance Toolbox™ in MATLAB, which includes several specialized models developed for calculating RUL from various types of measured system data. These models are useful when you have historical data and information, such as: – failure histories of machines similar to the one to be diagnosed. The historical data for each member of the data ensemble is fitted to a model of identical structure; – a known threshold value of some condition indicator indicating failure; – data on how much time or how much use it took for similar machines to fail (service life). RUL estimation models provide methods for training a model using historical data and using it to make a remaining service life prediction. The term service life here refers to the useful life of a machine defined in terms of any quantity used to measure the service life of a system. Similarly, time evolution can mean the evolution of a value with usage, distance traveled, number of cycles, or another quantity that describes the service life. A general workflow for using RUL estimation models is: – create and configure the corresponding model object; – train the estimation model using the available historical data; – using test data of the same type as the available historical data, estimate the RUL of the test component. It is also possible to use the test data recursively to update the model as new data becomes available, i.e. track the evolution of the RUL prediction as new data becomes available.

Faults; diagnostics of the state of the technical system; prediction of faults; remaining useful life (RUL); health indicator; RUL similarity evaluator.

Введение. Актуальным и эффективным на сегодня подходом к техническому обслуживанию и ремонтам (ТОиР) являются методы прогнозного и проактивного обслуживания, основанные на прогнозе технического состояния [1] и оценке рисков [2]. Это связано с повышением текущего уровня техники и стремительного развития информационных технологий.

При использовании технологий раннего диагностирования и прогнозирования технического состояния оборудования конечной целью предприятий является техническое обслуживание в тот момент, когда это наиболее рентабельно. Благодаря этому решается задача по снижению вероятности внепланового простоя, вызванного не выявленным своевременно дефектом или износом, а также сокращение затрат на проведение ТОиР, что в свою очередь повышает безотказность и рентабельность производства, экономит время и деньги на плановые ремонты. Дополнительными преимуществами является: увеличение срока службы оборудования, повышение безопасности производства, уменьшение количества аварий и оптимизация комплектов запасных частей и принадлежностей (ЗИП) и материалов.

Технически эту задачу можно сформулировать как определение оставшегося срока службы, для чего существуют разные инструменты, например, кривая Айова (Survivor Iowa) [3].



В данной статье рассматривается применение для решения данной задачи основе модели сходства оставшегося полезного срока службы.

Модели оценки RUL. Модели RUL полезны, когда имеются исторические данные и информация, такие как:

- ◆ Истории выполнения к отказу машин
- ◆ Известное пороговое значение некоторого индикатора состояния, который указывает на отказ
- ◆ Данные о том, сколько времени или сколько использования потребовалось для подобных машин, чтобы достигнуть отказа (время жизни)

Модели оценки RUL предоставляют методы для обучения модели с помощью исторических данных и с помощью него для выполнения прогноза остающегося срока полезного использования. Термин lifetime здесь относится к жизни машины, заданной с точки зрения любого количества, которое используется, чтобы измерить системную жизнь.

Общий рабочий процесс для использования моделей оценки RUL включает следующие шаги:

- ◆ Выберите лучший тип модели оценки RUL для данных и системного знания. Создайте и сконфигурируйте соответствующий объект модели.
- ◆ Обучите модель оценки использование исторических данных.

- ♦ Используя тестовые данные того же типа как исторические данные, оцените RUL тестового компонента

Данные RUL. Мониторинг состояния сложного объекта или процесса необходим для раннего выявления опасных ситуаций или их устранения с незначительными потерями. Исходной информацией для мониторинга служат данные, снимаемые с датчиков, которые характеризуют изменения параметров отслеживаемого объекта. На основе этой информации возможно прогнозирование отдельных параметров объекта. В этом случае, при условии реализации этого процесса в реальном времени возможна оценка состояния объекта на последующие временные промежутки, следующие за текущим. Таким образом, вопросы прогнозирования параметров являются актуальными для обеспечения безопасности функционирования сложных объектов и процессов.

Применение метода на основе модели сходства для прогнозирования неисправностей будет показано на демонстрационном примере MATLAB (<https://www.mathworks.com/help/predmaint/ug/similarity-based-remaining-useful-life-estimation.html>), описывающем, как построить полный рабочий процесс оценки оставшегося полезного срока службы (RUL), включая этапы предварительной обработки, выбора трендовых функций, построения индикатора работоспособности путем объединения датчиков, обучения оценщиков сходства RUL и проверки эффективности прогнозирования. В примере используются данные обучения из набора данных "PHM08 Challenge Data Set", NASA Ames Prognostics Data Repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames Research Center, Moffett Field, CA. [4].

Данные о деградации технического устройства содержат 260 выборок данных, описывающих работу до отказа. Эту группу измерений называют «ансамблем». Каждый участник ансамбля представляет собой таблицу с 26 столбцами. Столбцы содержат данные об идентификаторе машины, отметке времени, 3 рабочих условиях и 21 измерении датчика. Для целей исследования необходимо разделить данные о деградации на набор обучающих данных и набор проверочных данных для последующей оценки производительности. Для этого необходимо все доступные данные разбить на три временных отрезка: где отрезки 1 и 2 должны содержать данные только при нормальной работе оборудования. Отрезок 1 должен содержать данные для обучения модели. Отрезок 2 – данные для тестовой выборки (оценка модели и определения средней абсолютной ошибки прогнозирования значения параметра). Отрезок 3 – обязательно требуется наличие зафиксированных неисправностей.

Визуализируем часть данных (рис. 1):




Рис. 1. Визуализация данных ансамбля

Как видно по визуализации, нет четкой тенденции, показывающей процесс деградации в каждом измерении от запуска до отказа. Для извлечения более четких тенденций деградации из сигналов датчиков будут использоваться рабочие условия, каждый член ансамбля содержит 3 рабочих условия: «op_setting_1», «op_setting_2» и «op_setting_3».

Предварительная обработка данных. Первой задачей будет кластеризация данных, цель которой определение основных рабочих режимов. Для этого применяется алгоритм К-средних. Основная идея алгоритма k-средних заключается в том, что данные произвольно разбиваются на кластеры, после чего итеративно перевычисляется центр масс для каждого кластера, полученного на предыдущем шаге, затем векторы разбиваются на кластеры вновь в соответствии с тем, какой из новых центров оказался ближе по выбранной метрике. Цель алгоритма заключается в разделении n наблюдений на k кластеров таким образом, чтобы каждое наблюдение принадлежало ровно одному кластеру, расположенному на наименьшем расстоянии от наблюдения.

Визуализируем результаты кластеризации и выявленные центроиды кластеров.




Рис. 2. Результаты кластеризации

Как видно из графика, алгоритм кластеризации нашел 6 рабочих режимов.

Далее проводим первичную обработку данных, прежде всего нормализацию измерений, сгруппированных по различным рабочим режимам. Для этого используются методы статистической обработки данных [5]. Вычисляем среднее значение и стандартное отклонение каждого измерения датчика, сгруппированного по рабочим режимам.

Статистику в каждом режиме используем для нормализации данных обучения. Для каждого члена ансамбля извлекаются рабочие точки каждой строки, вычисляется его расстояние до каждого центра кластера и находится ближайший центр кластера. Затем для каждого измерения датчика вычитается среднее значение и делится на стандартное отклонение этого кластера. Если стандартное отклонение близко к 0, устанавливается нормализованное измерение датчика на 0, поскольку почти постоянное измерение датчика бесполезно для оценки оставшегося срока службы.

Визуализируем данные, нормализованные по рабочему режиму (рис. 3). Как видно, после нормализации удастся выделить некоторые тенденции деградации для некоторых измерений датчика.




Рис. 3. Данные после нормализации

Выбор трендовых функций. Теперь необходимо выбрать наиболее трендовые измерения датчика, чтобы построить индикатор работоспособности для прогнозирования. Идея использования этого инструмента состоит в том, что для описания степени износа оборудования используется некоторая функция, которая и получила название «индикатор здоровья» (Health Indicator, HI) или индикатор работоспособности. Аргументом этой функции является некоторый набор объективных параметров оборудования, а ее значение косвенно характеризует степень износа оборудования или узла при данном значении аргумента. Показатель HI предназначен для интегральной характеристики степени износа оборудования или его отдельных узлов. В настоящее время общепринятого подхода к конструированию HI не сформировано, ввиду объективно существующего различия как в принципах функционирования оборудования различных типов, так и в методах получения объективной информации относительно его текущего статуса. В зависимости от используемой модели представления HI, разработано и опробовано значительное число подходов оценивания его статуса [6]. В том числе регрессионные и авторегрессионные модели, различные варианты кластерного анализа, модели на основе нейронных сетей, скрытые марковские модели и ансамбли классификаторов [7–9]. Таким образом, индикатор работоспособности является основным инструментом прогнозирования, анализа надежности технической системы [10]. Трендовый подход в прогнозировании предполагает экстраполяцию выровненных значений динамического временного ряда прогнозируемого показателя. Прогноз-тренд – это прогноз, основанный на использовании линейной экстраполяции, сложившихся в прошлом тенденций. Таким образом, для выделения трендов используется линейная модель деградации и производится ранжирование наклонов сигналов.

Отсортируем наклоны сигнала и выберем 8 датчиков с наибольшими наклонами. Визуализируем выбранные трендовые измерения датчика (рис. 4).




Рис. 4. Трендовые измерения датчика

Следует обратить внимание, что некоторые из наиболее трендовых сигналов демонстрируют положительные тенденции, а другие – отрицательные.

Построение индикатора работоспособности. Для построения индикатора работоспособности для модели сходства используется следующий подход. Необходимо объединить измерения датчиков в один индикатор работоспособности, с помощью которого обучается модель на основе сходства.

Предполагается, что все данные о запуске до отказа начинаются с работоспособного состояния. Работоспособности в начале присваивается значение 1, а работоспособности при отказе присваивается значение 0. Предполагается, что работоспособность линейно ухудшается от 1 до 0 с течением времени. Эта линейная деградация используется для объединения значений датчиков.

Визуализируем состояние здоровья (рис. 5).




Рис. 5. Состояние здоровья

Состояние здоровья всех членов ансамбля меняется от 1 до 0 с различной скоростью ухудшения. Теперь подгоним линейную регрессионную модель состояния здоровья с наиболее трендовыми измерениями датчиков в качестве регрессоров и создадим единый индикатор работоспособности, умножив показания датчиков на соответствующие им веса. Визуализируем объединенный индикатор здоровья для обучающих данных (рис. 6).




Рис. 6. Объединенный индикатор здоровья

Данные с нескольких датчиков объединяются в один индикатор здоровья. Индикатор здоровья сглаживается фильтром скользящего среднего. Ту же операцию применяют к данным проверки и повторяют процесс нормализации режима и объединения датчиков с набором данных проверки. Визуализируем индикатор работоспособности для проверки данных (рис. 7).




Рис. 7. Индикатор работоспособности для проверки данных

Построение модели сходства RUL. Модели сходства или модели подобия основывают прогноз RUL тестовой машины на известном поведении подобных машин от исторической базы данных. Такие модели сравнивают тренд в тестовых данных или значениях индикатора состояния к той же информации, извлеченной от другой, аналогичной системы.

Модели подобия полезны когда:

- ◆ У вас есть данные выполнения к отказу из аналогичных систем, записи временных рядов [11]. Данные выполнения к отказу являются данными, которые запускаются во время здоровой операции и заканчиваются, когда машина находится в состоянии близко к отказу или обслуживанию.
- ◆ Данные выполнения к отказу показывают подобные поведения ухудшения. Таким образом, изменения данных некоторым характеристическим способом показывают, как система ухудшается.

Таким образом можно использовать модели подобия, когда можно получить так называемый профиль ухудшения из ансамбля данных. Профили ухудшения представляют эволюцию одного или нескольких индикаторов состояния для каждой машины в ансамбле как переходы машины от здорового состояния до дефектного состояния. Анализ таких моделей часто встречается при описании методов машинного обучения [12–13].

Теперь построим модель сходства RUL для данной задачи на основе остатков, используя данные обучения. В этой настройке модель пытается подогнать каждый объединенный набор данных к полиному 2-го порядка.

Расстояние между данными i и данными j вычисляется по 1-норме остатка

$$d(i,j)=||y_j-\hat{y}_{j,i}||_1,$$

где y_j – индикатор работоспособности машины j , $\hat{y}_{j,i}$ – оценочный индикатор работоспособности машины j с использованием полиномиальной модели 2-го порядка, идентифицированной в машине i .

Оценка сходства вычисляется по следующей формуле

$$score(i,j)=exp(-d(i,j)^2).$$

При наличии одного члена ансамбля в наборе проверочных данных модель найдет ближайшие 50 членов ансамбля в наборе обучающих данных, подберет распределение вероятностей на основе 50 членов ансамбля и будет использовать медиану распределения в качестве оценки RUL.

Оценка производительности. Одной из важнейших характеристик любого разработанного алгоритма является его производительность [14, 15]. Чтобы оценить производительность в модели RUL сходства, используем 50%, 70% и 90% выборочных данных проверки, чтобы спрогнозировать ее RUL.

Визуализируем проверочные данные, усеченные на 50%, и их ближайших соседей (рис. 8), и и распределение вероятностей расчетного RUL (рис. 9).

Существует относительно большая ошибка между оценочным RUL и истинным RUL, когда машина находится на промежуточной стадии работоспособности. В этом примере наиболее похожие 10 кривых близки в начале, но раздваиваются, когда приближаются к состоянию отказа, что приводит к примерно двум режимам в распределении RUL.




Рис. 8. Визуализация проверочных данных, усеченных на 50%




Рис. 9. Распределение вероятностей расчетного RUL (50%)

Используем данные проверки до второй точки останова, которая составляет 70% срока службы (рис. 10 и 11).




Рис. 10. Визуализация проверочных данных, усеченных на 70%




Рис. 11. Распределение вероятностей расчетного RUL (70%)

При наличии большего количества данных оценка RUL улучшается.

Теперь используем данные проверки до третьей точки останова, которая составляет 90% от срока службы (рис. 12 и 13).




Рис. 12. Визуализация проверочных данных, усеченных на 90%




Рис. 13. Распределение вероятностей расчетного RUL (90%)

Когда машина близка к отказу, оценка RUL в этом примере еще больше улучшается.

Теперь повторим ту же процедуру оценки для всего набора данных проверки и вычислим ошибку между оценочным RUL и истинным RUL для каждой точки останова. Визуализируем гистограмму ошибки для каждой точки останова вместе с ее распределением вероятностей [16] (рис. 14).




Рис. 14. Гистограмма ошибки и ее распределение вероятностей

Построим диаграмму ошибок прогнозирования, чтобы визуализировать медиану, 25-75 квантиль и выбросы (рис. 15).




Рис. 15. Диаграмма ошибок прогнозирования

И, наконец, вычислим и визуализируем среднее значение и стандартное отклонение ошибки прогноза (рис. 16).




Рис. 16. Среднее значение и стандартное отклонение ошибки прогноза

Тем самым показано, что ошибка становится более сконцентрированной около 0 (меньше выбросов) по мере увеличения количества наблюдаемых данных.

Заключение. В России предиктивная аналитика надежности в настоящее время находится на стартовых позициях, однако интерес к применению современных методов прогнозирования в промышленности растет [17, 18]. Как показывает практика, в результате внедрения решений прогнозной аналитики предприятиям разных отраслей удается уменьшить количество поломок оборудования в среднем на 30–35%, сократить расходы на его обслуживание на 10–20%, и на 10–15% увеличить объем производства [19]. Рассмотренный в данной статье метод предиктивной аналитики по прогнозированию неисправностей в технических системах на основе модели сходства оставшегося полезного срока службы позволяет производить оценку оставшегося полезного срока службы с достаточно высокой степенью точности (в статье показано, что ошибка становится более сконцентрированной около 0 по мере увеличения количества наблюдаемых данных, рисунок 16 дает возможность количественной оценки) и может успешно применяться для решения данного класса задач. Новизна предлагаемого подхода к прогнозированию возникновения неисправностей заключается в том, что модели сходства основывают прогноз RUL тестовой машины на известном поведении подобных машин из исторической базы данных. Такие данные легко доступны практически в любой технической системе. Такие модели сравнивают тенденцию в тестовых данных или значениях индикаторов состояния с той же информацией, извлеченной из других подобных систем. Применение этой модели особенно полезно, когда: – имеются в наличии данные о работе до отказа от подобных систем. Данные о работе до отказа – это данные, которые начинаются во время исправной работы и заканчиваются, когда машина находится в состоянии, близком к отказу или обслуживанию; – данные о работе до отказа показывают схожее поведение деградации. То есть данные изменяются некоторым характерным образом по мере того, как система деградирует. Таким образом особенно привлекательным является использование модели сходства, когда можно получить профили деградации из своего ансамбля данных. Профили деградации представляют собой эволюцию одного или нескольких индикаторов состояния для каждой машины в ансамбле по мере того, как машина переходит из исправного состояния в неисправное [20]. Особенность этой модели в том, что она работает с остатками. Оценка на основе остатков подгоняет предыдущие данные под модель, например, модель ARMA или модель, которая является линейной или экспоненциальной по времени использования. Затем она вычисляет остатки между данными, предсказанными из ансамблевых моделей, и данными из тестового компонента. Подход на основе остаточного сходства очень полезен, когда знания о системе включают форму для модели деградации.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Как сократить расходы на обслуживание оборудования на 40 %. Блог Кирилла Костанецкого. – URL: <https://nv.ua/techno/technoblogs/chto-takoe-prediktivnoe-obslyuzhivanie-2476568.html>.
2. Proactive Asset Management with IIoT and Analytics, ARC Advisory Group, January 15, 2015, By Ralph Rio.
3. Рейли Р., Швайс Р. Оценка нематериальных активов: пер. с англ. – М.: ИД «КВИНТО-КОНСАЛТИНГ», 2005. – 792 с.
4. Saxena A. and Goebel K. "PHM08 Challenge Data Set", NASA Ames Prognostics Data Repository. – <http://ti.arc.nasa.gov/project/prognostic-data-repository>. NASA Ames Research Center, Moffett Field, CA. – 2008.
5. Любимов И.В., Мешков С.А. Статистические методы контроля качества и надежности: учеб. пособие. Балт. гос. техн. ун-т. – СПб., 2010. – 96 с. – ISBN 978-5-85546-522-8.
6. Гаврилюк Е.А., Манцеров С.А., Панов А.Ю. Прогнозирование отказов систем автоматического управления газоперекачивающими агрегатами на основе индекса технического состояния и степени риска // Фундаментальные исследования. – 2015. – № 7-2. – С. 309-313.
7. Любимов И.В., Мешков С.А., Ушаков, А.П., Чалый Р.А. Методы и средства диагностирования технических систем: учеб. пособие. Балт. гос. техн. ун-т. – СПб., 2011. – 120 с. – ISBN 978-5-85546-863-8.

8. *Кашицкий Ю.С., Игнатов Д.И.* Ансамблевый метод машинного обучения, основанный на рекомендации классификаторов // *Machine Learning in Python, Journal of Machine Learning Research*. – 2011. – 12. – С. 2825-2830.
9. *Попова Т.П.* Ансамбли моделей как современный инструмент анализа данных / ответст. за выпуск: д. эконом. наук, ректор Уральского государственного экономического университета. – 2017. – 256 с.
10. *Шушмарев В.Ю.* Надежность технических систем: учебник для студ. высш. учеб. заведений. – М.: Издательский центр «Академия», 2010. – 304 с.
11. *Дюк В.А., Фомин В.В.* Прогнозирование временных рядов на основе методов DataMining // *Известия Санкт-Петербургского государственного технологического института (технического университета)*. – 2012. – № 13. – С. 108-111.
12. *Шаханов Н.И., Осолков В.М., Варфоломеев И.А., Юдина О.В.* Прогнозирование отказов оборудования на основе алгоритмов машинного обучения // *Вопросы образования и науки. По материалам международной научно-практической конференции*, 31 мая 2016. – С. 315-317.
13. *Флах П.* Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных. – М.: ДМК Пресс, 2015. – 402 с.
14. *Кормен Т., Лейзерсон Ч., Ривест Р., Штайн К.* Алгоритмы: построение и анализ. – 2-е изд., пер. с англ. – М., 2005. – 1296 с.
15. *Макконнелл Дж.* Основы современных алгоритмов. – 2-е изд., доп. – М.: Техносфера, 2004. – 368 с.
16. *Вадзинский Р.Н.* Справочник по вероятностным распределениям. – СПб., 2001.
17. *Чугреев В.Л., Баданин Д.А.* Использование прогнозной аналитики в информационно-аналитических системах поддержки принятия решений // *Молодой ученый*. – 2016. – № 6. – С. 49-52.
18. *Липатов М.* Первый в России комплекс предиктивной аналитики для энергетического и промышленного оборудования // *Экспозиция Нефть Газ*. – 2016. – № 3 (49). – С. 82-83.
19. Прогнозная аналитика – способ адаптации в новых экономических реалиях. – URL: <http://www.iksmedia.ru/articles/5292204-Prognoznaya-analitika-sposob-adapta.html>.
20. *Кобл Джейми Баалис.* Объединение источников данных для предсказания оставшегося срока полезного использования – автоматизированный метод для идентификации прогностических параметров. – 2010.

REFERENCES

1. *Kak sokratit' raskhody na obsluzhivanie oborudovaniya na 40 %*. Blog Kirilla Kostanetskogo [How to reduce equipment maintenance costs by 40%. Blog by Kirill Kostanetsky]. Available at: <https://nv.ua/techno/techoblogs/chto-takoe-prediktivnoe-obsluzhivanie-2476568.html>.
2. *Proactive Asset Management with IIoT and Analytics*, ARC Advisory Group, January 15, 2015, By Ralph Rio.
3. *Reyli R., Shveys R.* Otsenka nematerial'nykh aktivov [Evaluation of intangible assets]: transl. from english. Moscow: ID «KVINTO-KONSALTING», 2005, 792 p.
4. *Saxena A. and Goebel K.* "PHM08 Challenge Data Set", NASA Ames Prognostics Data Repository. Available at: <http://ti.arc.nasa.gov/project/prognostic-data-repository>. NASA Ames Research Center, Moffett Field, CA, 2008.
5. *Lyubimov I.V., Meshkov S.A.* Statisticheskie metody kontrolya kachestva i nadezhnosti: ucheb. posobie [Statistical methods of quality and reliability control: a tutorial]. Baltic State Technological University. St. Petersburg., 2010, 96 p. ISBN 978-5-85546-522-8.
6. *E.A., Mantserov S.A., Panov A.Yu.* Prognozirovaniye otkazov sistem avtomaticheskogo upravleniya gazoperekachivayushchimi agregatami na osnove indeksa tekhnicheskogo sostoyaniya i stepeni riska [Forecasting failures of automatic control systems of gas pumping units based on the technical condition index and risk degree], *Fundamental'nye issledovaniya* [Fundamental research], 2015, No. 7-2, pp. 309-313.
7. *Lyubimov I.V., Meshkov S.A., Ushakov, A.P., Chalyy R.A.* Metody i sredstva diagnostirovaniya tekhnicheskikh sistem: ucheb. posobie [Methods and tools for diagnosing technical systems: a tutorial]. Baltic State Technological University. St. Petersburg., 2011, 120 p. ISBN 978-5-85546-863-8.
8. *Kashnitskiy Yu.S., Ignatov D.I.* Ansamblevyi metod mashinnogo obucheniya, osnovannyi na rekomendatsii klassifikatorov [Ensemble method of machine learning based on classifier recommendations], *Machine Learning in Python, Journal of Machine Learning Research* [Machine Learning in Python, Journal of Machine Learning Research], 2011, 12, pp. 2825-2830.

9. *Popova T.P.* Ansambli modeley kak sovremennyy instrument analiza dannykh [Model ensembles as a modern tool for data analysis], responsible for the release: dr. of econ. sc., Rector of the Ural State University of Economics, 2017, 256 p.
10. *Shishmarev V.Yu.* Nadezhnost' tekhnicheskikh sistem: uchebnik dlya stud. vyssh. ucheb. zavedeniy [Reliability of technical systems: textbook for students of higher educational institutions]. Moscow: Izdatel'skiy tsentr «Akademiya», 2010, 304 p.
11. *Dyuk V.A., Fomin V.V.* Prognozirovaniye vremennykh ryadov na osnove metodov DataMining [Forecasting of time series based on DataMining methods], *Izvestiya Sankt-Peterburgskogo gosudarstvennogo tekhnologicheskogo instituta (tekhnicheskogo universiteta)* [Bulletin of the St. Petersburg State Technological Institute (Technical University)], 2012, No. 13, pp. 108-111.
12. *Shakhanov N.I., Oskolkov V.M., Varfolomeev I.A., Yudina O.V.* Prognozirovaniye otkazov oborudovaniya na osnove algoritmov mashinnogo obucheniya [Forecasting of equipment failures based on machine learning algorithms], *Voprosy obrazovaniya i nauki. Po materialam mezhdunarodnoy nauchno-prakticheskoy konferentsii, 31 maya 2016* [Issues of education and science. Based on the materials of the international scientific and practical conference, May 31, 2016], pp. 315-317.
13. *Flakh P.* Mashinnoe obucheniye. Nauka i iskusstvo postroyeniya algoritmov, kotorye izvlekayut znaniya iz dannykh [Machine learning. The science and art of building algorithms that extract knowledge from data]. Moscow: DMK Press, 2015, 402 p.
14. *Kormen T., Leyzerson Ch., Rivest R., Shtayn K.* Algoritmy: postroyeniye i analiz [Algorithms: construction and analysis]. 2nd ed.: transl. from engl. Moscow, 2005, 1296 p.
15. *Makkonnell Dzh.* Osnovy sovremennykh algoritmov [Fundamentals of modern algorithms]. 2nd ed. Moscow: Tekhnosfera, 2004, 368 p.
16. *Vadzinskiy R.N.* Spravochnik po veroyatnostnym raspredeleniyam [Handbook of probability distributions]. St. Petersburg, 2001.
17. *Chugreev V.L., Badanin D.A.* Ispol'zovaniye prognoznoy analitiki v informatsionno-analiticheskikh sistemakh podderzhki prinyatiya resheniy [Using Predictive Analytics in Information and Analytical Systems for Decision Support], *Molodoy uchenyy* [Young Scientist], 2016, No. 6, pp. 49-52.
18. *Lipatov M.* Pervyy v Rossii kompleks prediktivnoy analitiki dlya energeticheskogo i promyshlennogo oborudovaniya [The first predictive analytics complex for energy and industrial equipment in Russia], *Ekspozitsiya Neft' Gaz* [Expositsiya Neft Gas], 2016, No. 3 (49), pp. 82-83.
19. Prognoznaya analitika – sposob adaptatsii v novykh ekonomicheskikh realiyakh [Predictive analytics - a way to adapt to new economic realities]. Available at: <http://www.iksmedia.ru/articles/5292204-Prognoznaya-analitika-sposob-adapta.html>.
20. *Kobl Dzhemy Baalis.* Ob'edineniye istochnikov dannykh dlya predskazaniya ostavshegosya sroka poleznogo ispol'zovaniya – avtomatizirovannyy metod dlya identifikatsii prognosticheskikh parametrov [Combining data sources to predict remaining useful life - an automated method for identifying prognostic parameters], 2010.

Кораблев Юрий Анатольевич – Санкт-Петербургский государственный электротехнический университет СПбГЭТУ «ЛЭТИ» им. В.И. Ульянова (Ленина); e-mail: juri.korablev@gmail.com; г. Санкт-Петербург, Россия; тел.: +79213940822; кафедра автоматизации и процессов управления; доцент.

Korablev Yuri Anatol'evich – St. Petersburg state electrotechnical University named after V.I. Ulyanov (Lenin) SPbGETU "LETI"; e-mail: juri.korablev@gmail.com; Saint Petersburg, Russia; phone: +79213940822; the Department of Automation and Control Processes; associate professor.

УДК 004.067

DOI 10.18522/2311-3103-2024-6-155-163

А.С. Маннаа, Г.В. Муратова

РАЗРАБОТКА СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ ОЦЕНКИ ТЯЖЕСТИ ОСТЕОАРТРИТА КОЛЕННОГО СУСТАВА

Предлагается метод автоматизированной оценки степени тяжести остеоартрита коленного сустава, основанный на применении современных методов машинного обучения, в частности, глубокой нейронной сети. Остеоартрит является одним из наиболее распространенных дегенеративных заболеваний суставов, и его своевременная диагностика является критически важной для эффективного лечения. Традиционные методы визуальной оценки рентгенографических снимков