

УДК 004.02

DOI: [10.26102/2310-6018/2020.29.2.037](https://doi.org/10.26102/2310-6018/2020.29.2.037)

Классификационный подход на основе комбинации глубоких нейронных сетей для прогнозирования отказов сложных многообъектных систем

В.К. Сай, М.В. Щербаков

Федеральное государственное бюджетное образовательное учреждение высшего образования «Волгоградский государственный технический университет», Волгоград, Российская Федерация

Резюме: Научно-технический прогресс способствовал бурному росту сложности систем и выполняемых ими функций, что особенно характерно для различных отраслей современной промышленности. Здесь цена отказа или сбоя оборудования может быть очень высокой а иногда и привести к неопределимым потерям, связанным с гибелью людей. Обслуживание подобных систем требует высоких материальных затрат, и всё же не исключает возможного возникновения сбоев. Это свидетельствует о том, что задача обеспечения надежности сложных многообъектных систем еще далека от своего решения. В связи с этим в настоящее время на первое место выходит задача обеспечения надежного функционирования систем при минимизации затрат на их содержание и техническое обслуживание. Решение которой невозможно без разработки и внедрения интеллектуальных систем, выполняющих функции предсказательной аналитики и предсказательного технического обслуживания. В данной статье предлагается гибридная нейросетевая модель прогнозирования отказов сложных многообъектных систем на основе классификационного подхода, направленная на повышение эксплуатационной надежности оборудования при минимальных затратах. Представлены результаты вычислительных экспериментов, подтверждающие высокую эффективность предложенного решения.

Ключевые слова: прогнозирование отказов, методы на основе данных, глубокие нейронные сети, LSTM, CNN.

Для цитирования: Сай В.К., Щербаков М.В. Классификационный подход на основе комбинации глубоких нейронных сетей для прогнозирования отказов сложных многообъектных систем *Моделирование, оптимизация и информационные технологии*. 2020;8(2). Доступно по: https://moit.vivt.ru/wp-content/uploads/2020/05/SaiShcherbakov_2_20_1.pdf DOI: 10.26102/2310-6018/2020.29.2.037

A classification approach based on a combination of deep neural networks for predicting failures of complex multi-object systems

V.C. Sai, M.V. Shcherbakov

Federal State Budgetary Educational Institution of Higher Education "Volgograd State Technical University", Volgograd, Russian Federation

Abstract: Scientific and technical progress has contributed to a rapid increase in the complexity of systems and their functions, which is especially characteristic of various fields of modern industry. Here, the cost of failure of equipment can be very high and sometimes lead to invaluable losses associated with the loss of life. Maintenance of such systems requires high material costs, but still does not exclude the possibility of failures. This indicates that the problem of ensuring the reliability of complex multi-object systems is still far from being solved. In this regard, the task of ensuring reliable operation of systems while minimizing the cost of their maintenance and maintenance is now in the first place. The solution of this problem is impossible without the development and implementation of intelligent systems that perform the functions of predictive analytics and predictive maintenance. This article

proposes a hybrid neural network model for predicting failures of complex multi-object systems based on the classification approach, aimed at improving the operational reliability of equipment at minimal cost. The results of computational experiments confirming the high efficiency of the proposed solution are presented

Keywords: Forecasting failures, data-driven methods, deep neural networks, LSTM, CNN.

For citation: Sai V.C., Shcherbakov M.V. A classification approach based on a combination of deep neural networks for predicting failures of complex multi-object systems. *Modeling, Optimization and Information Technology*. 2020;8(2). Available from: https://moit.vivt.ru/wp-content/uploads/2020/05/SaiShcherbakov_2_20_1.pdf DOI: 10.26102/2310-6018/2020.29.2.037 (In Russ).

Введение

Обеспечение надежного и бесперебойного функционирования оборудования на этапе эксплуатации с минимальными затратами является приоритетной и актуальной задачей для различных производств [1]. В современных условиях, характеризующихся следующими факторами: (1) быстрым ростом сложности многообъектных целевых технических систем и выполняемых ими функций; (2) возрастающими рисками, связанными с простоями оборудования; (3) ужесточением требований к выполнению требований техники безопасности на производстве и охране окружающей среды, проблема надежности функционирования оборудования является критической. Здесь цена отказов и простоев оборудования может быть очень высокой а иногда и привести к неопределимым потерям, связанным с гибелью людей.

Классическая система планово-предупредительных ремонтов (ППР), которая в данный момент используется большинством предприятий, при таких условиях в значительной мере теряет свою эффективность и не удовлетворяет требованиям современной промышленности. Это обуславливает повышение роли методов прогнозирования технического состояния и прогнозирования остаточного ресурса (Remaining Useful Life, RUL) для перехода к более прогрессивной стратегии «Ремонт по состоянию». Данная стратегия, основанная на использовании предиктивного подхода к техническому обслуживанию, в зарубежной литературе получила название «предсказательное техническое обслуживание» (Predictive Maintenance, PdM). Достоверна оценка RUL и вероятности наступления отказа оборудования является основанием для принятия оптимального решения при выборе стратегии воздействия на оборудование. Такие решения, принятые на основе достоверного прогноза RUL, обеспечивают соблюдение оптимального баланса между затратами на проведение технологических воздействий (операций) и величиной потенциальных ущербов и рисков от отказов оборудования.

В последнее время в рамках внедрения концепции «Индустрия 4.0» для построения предсказательных моделей для PdM наиболее перспективными представляются подходы, основанные на обработке больших массивов многомерных сенсорных данных с использованием методов машинного обучения [3]. Одними из наиболее широко используемых классических методов машинного обучения для решения задачи прогнозирования отказов являются метод опорных векторов (Support-Vector Machine, SVM) [4, 5], алгоритм случайного леса (Random Forest, RF) и алгоритм градиентного бустинга (Gradient Boosting, GB) [6]. Однако чистые собранные данные из современных промышленных систем имеют сложную структуру и зачастую являются избыточными и зашумленными. Поэтому для достижения приемлемых результатов прогнозирования требуются большие усилия в рамках методов извлечения признаков с использованием экспертных знаний предметной области, так как эффективность

прогностической модели напрямую зависит от «качества» признаков. Это как правило, приводит к низкой эффективности и низкой обобщающей способности модели, поскольку извлечение признаков специфично для конкретного сценария проблемы. Вместе с тем, в последнее время в рамках мониторинга состояния и диагностики неисправностей наиболее перспективным представляются методы глубокого обучения (глубокие нейронные сети) [3]. Это обусловлено тем, что сети могут автоматически выделять нужные признаки из больших массивов многомерных данных, устраняя необходимость в ручном конструировании признаков (feature engineering) с помощью экспертов, которая является фундаментом для классических алгоритмов машинного обучения. Среди наиболее применяемых глубоких нейронных сетей выделим сверточные нейронные сети (Convolutional neural network, CNN) [7] и рекуррентные нейронные сети долгой краткосрочной памяти (Long short-term memory, LSTM) [8]. В работе [2] предложенный нами гибридный метод на основе комбинации сетей CNN и LSTM дал превосходный результат по сравнению с альтернативными методами при прогнозировании RUL авиационных газотурбинных двигателей.

Все вышеописанные методы используют подход на базе регрессионных моделей. Однако результаты исследования в работе [2] показали, что точность прогнозирования RUL в значительной мере зависит от горизонта прогнозирования (интервал между текущим моментом времени (моментом прогнозирования) до момента возникновения отказа оборудования). Имеются регрессионные модели дают более точные прогнозы когда оборудование находится ближе к моменту отказа, это иллюстрирует Рисунок 1. Поэтому использование прогнозного значения RUL на первой стадии работы оборудования может привести к ошибочным решениям. Для решения этой проблемы, в данной работе предлагается новый метод прогнозирования отказа оборудования на основе классификационного подхода с использованием модифицированной гибридной нейросетевой модели CNN-LSTM, предложенной нами в работе [2].




Рисунок 1 – Пример выхода гибридной нейронной сети CNN-LSTM по сравнению с фактическими значением RUL

Figure 1 – Example of CNN-LSTM hybrid neural network output versus target output

Постановка задачи

Пусть имеются значения характеристик, записанные в течение эксплуатационного срока набора нескольких единиц однотипного оборудования, обозначаем этот набор как D . Датчики являются источниками информации о состоянии узлов и агрегатов оборудования и об условиях его эксплуатации. Для каждой единицы оборудования $id_i \in D, i = 1, \dots, m$ сенсорные данные могут быть представлены в виде многомерных временных рядов $X^{(i)} = \{x_1^{(i)}, x_2^{(i)}, \dots, x_{T^{(i)}}^{(i)}\}$, где $T^{(i)}$ – длина временных рядов для i -ой единицы оборудования, $x_t^{(i)} \in \mathbb{R}^n$ – n -мерный вектор, представляющих собой показания n датчиков в момент времени t . При этом часть сигналов $x_t^{(s)} \in \mathbb{R}^s$

может поступать с датчиков, характеризующих состояния узлов и агрегатов оборудования а часть $x_t^{(c)} \in \mathbb{R}^c$ из датчиков, характеризующих условия его эксплуатации, $n = s + c$. Техническое состояния каждой единицы оборудования $id_i \in D$ характеризуется вектором $x_t^{(i)}$. В реальных системах поддержки функционирования оборудования отсутствует практическая необходимость рассматривать более чем три группы значения параметра $C = \{C_n, C_w, C_c\}$:

C_n : «Normal» – нормальное состояние оборудования. Ремонт не требуется

C_w : «Warning» – приближение к предотказному состоянию. Необходимо планирование ремонтов

C_c : «Critical» – критическое состояние оборудования. Эксплуатация недопустима. Требуется срочное воздействие на оборудование.

Априорная информация, которая представлена обучающим множеством $D = \{(x^j, C^j)\}, j = \overline{1, L}$, заданым Таблицей, каждая строка j которой содержит векторное описание объекта $x = \varphi(id_i)$ и метку класса $C_k \in C = \{C_n, C_w, C_c\}$. Заметим, что обучающее множество характеризует неизвестное отображение: $f^* := \varphi \rightarrow C$.

Требуется по поступающим фрагментам (последовательностям) I_t непрерывных данных из датчиков и априорной информации, заданной обучающим множеством $D = \{(x^j, C^j)\}, j = \overline{1, L}$, найти отображение: $f^* := I_t \rightarrow C_k$, позволяющее одновременно решить две важных задачи: идентифицировать стадии деградации системы и определить возможные отказы системы в различных будущих временных интервалах.

Предлагаемый метод

Предлагаемый метод прогнозирования заключается в анализе имеющихся данных об историческом поведении сложных многообъектных систем для формирования прогнозных моделей. Полученные модели затем используются для выработки рекомендаций оптимального использования оборудования в онлайн режиме. Архитектура, реализующая данный подход представлена на Рисунке 2.

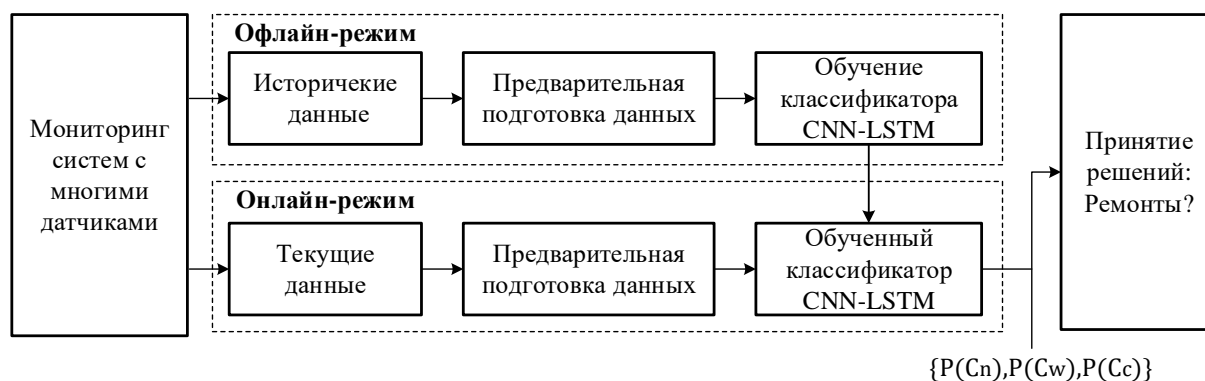


Рисунок 2 – Предлагаемый подход прогнозирования отказов сложных многообъектных систем

Figure 2 – The proposed approach to predicting failures of complex multi-object systems

В настоящей работе для решения задачи (задачи многоклассовой классификации) предлагается гибридная нейросетевая модель CNN-LSTM, сочетающая одномерную сверточную нейронную сетей (1D CNN) и рекуррентную нейронную сеть долгой краткосрочной памяти (LSTM) (Рисунок 3). Основными преимуществами предлагаемого решения являются: (i) применение сетей 1D CNN позволяет автоматически снижать размерность данных и извлекать нужные признаки из «сырых» необработанных данных

с датчиков сквозным образом, что устраняет необходимость в ручном конструировании признаков, которое специфично для конкретного сценария проблемы и сильно зависит от опыта предметной области (ii) применение сетей LSTM позволяет моделировать долговременные зависимости между временными шагами, то есть учитывает последовательный характер информации с датчиков. Обоснование выбора и эффективности данной комбинации приведено в наших работах [1, 2]. Модель включает полностью связанную нейронную сеть с тремя выходами для формирования вероятностей принадлежности к трем классам.

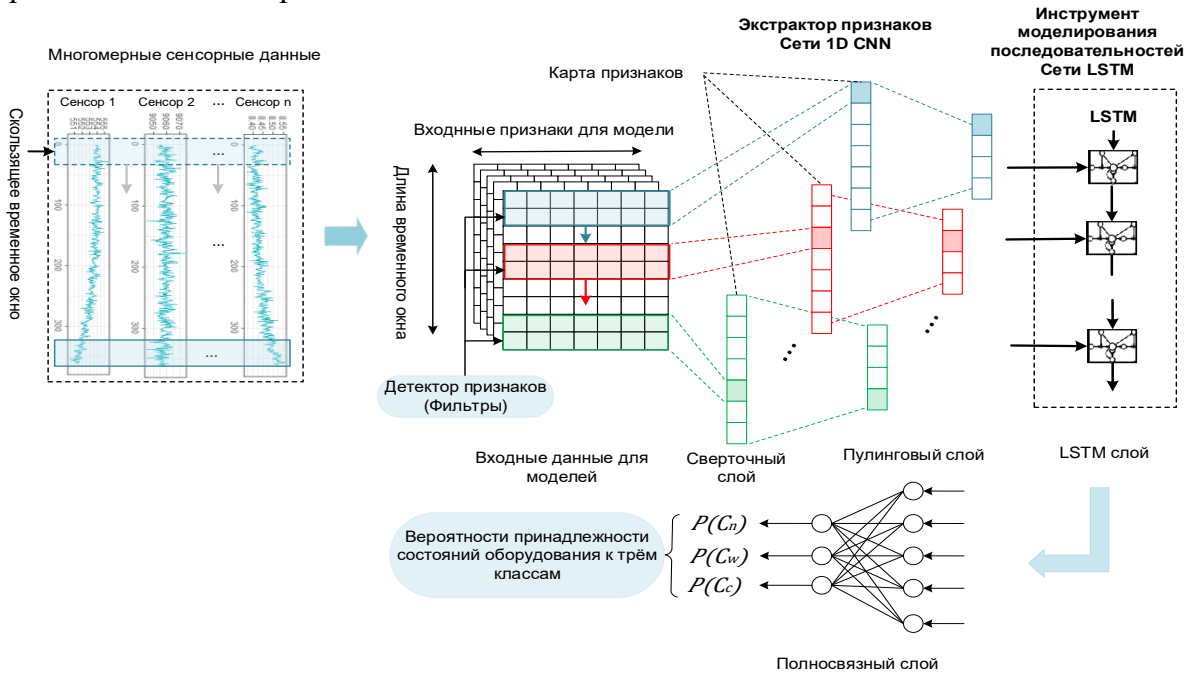


Рисунок 3 – Архитектура гибридной нейросетевой модели CNN-LSTM для прогнозирования отказа сложных многообъектных систем.

Figure 3 – Architecture of the CNN-LSTM hybrid neural network model for predicting failure of complex multi-object systems.

Перед обучением сети, была сформирована целевая переменная $RUL(t)$ для каждого оборудования $id_i \in D$ следующим образом: $RUL^{(i)}(t) = T^{(i)} - t^{(i)}$, где $T^{(i)}$ – момент времени, на котором произошёл отказ для оборудования id_i , $t^{(i)}$ – текущее время наблюдения за его работой (Рисунок 4).




Рисунок 4 – Иллюстрация к изменению состояния оборудования и наступления отказа
 Figure 4 – The Illustration of remaining useful life

Для формирования классов $C = \{C_n, C_w, C_c\}$ назначаем два горизонта w_0 и w_1 ($w_0 < w_1$) (Рисунок 5). На основе этих горизонтов формируются классы следующим образом: первый класс – «класс 0», представляет собой случай, когда $RUL > w_1$ (группа состояний C_n); второй класс – «класс 1», характеризует случай, когда RUL в периоде $[w_0, w_1]$, то есть $w_0 \leq RUL < w_1$ (группа состояний C_w). И наконец, третий класс, отмеченный «класс 2», относится к тому случаю, когда RUL не будет превышать w_0 , то есть $RUL \leq w_0$ (группа состояний C_c).




Рисунок 5– Иллюстрация процесса формирования классов
 Figure 5 – Illustration of the class formation process

Процесс подготовки данных для обучения нейронных сетей включает следующие шаги:

Шаг 1. Выбор признаков. Обнаружение и удаление признаков с очень низкой дисперсией (околонулевой дисперсией) так как они не дают ценной информации:

$$inputfeature = \{x: \text{дисперсия} = \frac{1}{m} \sum_{i=1}^m (x_i - \hat{x})^2 \neq 0\},$$

Шаг 2. Нормализация данных. Следует отметить, что значения, полученные от разных сенсоров имеют значения, относящиеся к самым разным диапазонам. Поэтому для улучшения работы нейронных сетей воспользуемся Min-max нормализацией данных в пределах $[0, 1]$:

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}},$$

Шаг 3. Формирование входных данных для обучения модели. Нейронные сети будут принимать в качестве входных данных последовательности значений. Для этого используем скользящее окно фиксированного размера L для формирования трехмерных тензоров с формой (*образцы, метки_времени, признаки*).

Критическим моментом при обучении является недопущение переобучения (overfitting) сети. Для этого в рамках данной работы используются два приема регуляризации нейронных сетей:

1. прореживание (*dropout*) – один из наиболее эффективных и распространенных приемов регуляризации для нейронных сетей, разработанный Джеффом Хинтоном (Geoff Hinton) и его студентами в Университете Торонто [8]. Прореживание, которое применяется к слою, заключается в удалении (присваивании нуля) случайно выбираемым признакам на этапе обучения.
2. ранняя остановка – прерывание обучения, когда оценка потерь на валидационных данных перестает улучшаться (при этом сохраняется лучший вариант модели, полученный в ходе обучения)

Эксперименты и обсуждение

Для обоснования эффективности предлагаемой модели были проведены вычислительные эксперименты, реализация которых осуществлялась с помощью программы, написанной на языке Python. Нейросетевые модели были реализованы с использованием модульной библиотеки Keras [10], функционирующей поверх библиотек TensorFlow от Google [11].

Для проведения экспериментов был использован набор данных FD001 из широко известной базы данных C-MAPPS Dataset (NASA) [5], который содержит показания сенсоров в полете, имитирующих поведение однотипных авиационных газотурбинных двигателей и условия их работы. Этот набор включает в себя обучающую выборку и тестовую выборки. Обе они содержат информацию по 100 двигателям. Каждый двигатель в обучающей выборке работает до отказа, а каждый двигатель в тестовой выборке – до определенного момента времени, предшествующего отказу. На основе данных из обучающей выборки необходимо предсказать отказ для каждого двигателя в тестовой выборке. RUL в данном случае выражены в летных циклах.

Были установлены два временных интервала $w_0 = 15$ и $w_1 = 30$. То есть модель предсказывает вероятности того, что двигатели находятся в трех различных временных горизонтах: $(RUL \leq 15)$, $(15 < RUL \leq 30)$, $(RUL > 30)$. Для трех возможных классов C_n , C_w и C_c в соответствии с байесовским правилом выбирается класс C_n , если $P_{C_n}(I_t) > P_{C_w}(I_t)$ и $P_{C_n}(X) > P_{C_c}(I_t)$.

Обучение нейросетевых моделей производилось на облачном сервисе Google Colaboratory (также известного как Colab) с графическим процессором GPU NVidia Tesla K80 с 12 Гб видеопамати.

Для оптимизации гиперпараметров (параметров настройки модели используется приём случайного поиска (Random Search) с помощью фреймворка Keras-Tuner [12]. Результат в виде оптимальных гиперпараметров для предложенной модели показан в Таблице 1.

Таблица 1 – Набор полученных оптимальных гиперпараметров для модели
 Table1 – A set of obtained optimal hyperparameters for the model

№	Тип слоя	Фильтры/ нейроны	Размер фильтра	Регион	Функция активации	Коэффициент прореживания
1	Conv1D	32	5	-	relu	-
2	Conv1D	64	3	-	relu	-
3	MaxPooling1D	-	-	3	-	-
4	LSTM	50	-	-	-	0.2
5	LSTM	50	-	-	-	-
6	Dense	3	-	-	sigmoid	-

В данной работе мы не только прогнозируем, к какому классу принадлежит последовательность данных, но и представляем вероятность того, что она принадлежит к каждому классу. Поэтому для оценки эффективности предложенного классификатора используется матрица ошибок (*Confusion matrix*) классификации $M = \{m_{ij}\}_{i,j=1}^N$. Данная матрица показывает количества объектов, реально принадлежащих классу C_i , но отнесенных к C_j .

Таблица 2 показывает значения матрицы ошибок многоклассовой классификации на данных по тестовым двигателям. Диагональные элементы соответствуют правильным классификациям, а внедиагональные – неправильным.

Таблица 2 – Матрица ошибок многоклассовой классификации
 Table 1 – Confusion matrix for multiclass classifier

	Класс 0	Класс 1	Класс 2
Прогнозный класс 0	9678	86	0
Прогнозный класс 1	18	239	15
Прогнозный класс 2	0	1	59

Точность классификации, выполняемая предложенной гибридной нейросетевой моделью, определяется как:

$$Accuracy = \frac{N_c}{N},$$

где N_c – доля классифицированных объектов, по которым модель приняла правильное решение при обработке N объектов.

Точность классификации для предложенной гибридной модели на тестовых двигателях показана в Таблице 3.

Таблица 3 – Точность классификации состояний двигателей на данных по тестовым двигателям
Table 3 – Classification accuracy on the test engines

Класс	Точность (%)
Класс 0	$\frac{9678}{(9678 + 86)} * 100 = 99\%$
Класс 1	$\frac{239}{(18 + 15)} * 100 = 88\%$
Класс 2	$\frac{59}{(59 + 1)} * 100 = 98\%$

По результатам Таблиц 2 и 3 можно сделать следующие выводы: i) полученный результат вполне адекватен для практического использования предложенного метода, так как модель определяет текущее состояние двигателей с высокой достоверностью ii) когда двигатель находится в группе состояний C_w (класс 1: $15 < RUL \leq 30$) классификатор дает меньшую точность по сравнению с группами C_n (класс 0: $RUL > 30$) и C_c (класс 2: $RUL \leq 15$). Это объясняется тем, что два временных горизонта w_0 и w_1 находятся так близко друг другу. Следовательно, характеристики двигателей, принадлежащие группе состояний C_w аналогичны характеристикам групп состояний w_0 и w_1 .

Для более подробной иллюстрации, посмотрим Таблицу 4, которая показывает некоторые последние периоды жизненного цикла двигателя $id = 32$ в тестовой выборке. В первом столбце представлены фактические значения RUL, три следующие столбцы показывают вероятности того, что двигатель принадлежит к трем классам: класс 0 (C_n : $RUL > 30$), класс 1 (C_w : $15 < RUL \leq 30$) и класс 2 (C_c : $RUL \leq 15$). Рисунок 6 иллюстрирует результаты применения предложенного классификатора при определении вероятностей принадлежности состояний двигателя $id = 32$ к трём классам при наработке $t = 183$ (фактическое значение $RUL = 203 - 183 = 20$).

Таблица 4 – Вероятности принадлежности к классам для двигателя $id = 32$ из тестовой выборки
Table 4 – Class membership probabilities of the predicted classes for the engine with $id = 32$ in the test set

Фактические RUL	Класс 0 (%)	Класс 1 (%)	Класс 2 (%)
50	99.44	0.06	0
40	98.82	1.17	0.01
20	0.39	95.20	4.41
15	0.01	7.06	92.93
8	0	0.08	99.92

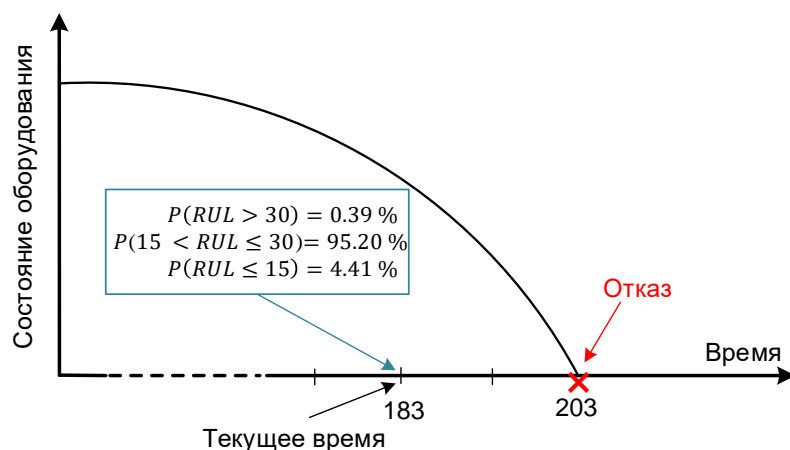


Рисунок 6 – Иллюстрация результатов, полученных предлагаемой моделью на каждом временном шаге для двигателя $id = 32$ в тестовой выборке
Figure 6 – Illustration of the class membership probabilities of the predicted classes at each time step for the engine with $id = 32$ in the test set

Полученный результат вполне адекватен для практического использования предложенного метода, так как модель определяет текущее техническое состояние системы с высокой достоверностью.

Заключение

Таким образом, в работе предложен классификационный подход на основе комбинации глубоких нейронных сетей для прогнозирования отказов сложных многообъектных систем. По итогам работы можно сделать вывод об эффективности и высокой точности разработанного классификатора на основе комбинации сверточной нейронной сети (1D CNN) и рекуррентной нейронной сети долгой (LSTM) для решения задачи прогнозирования отказов сложных многообъектных систем. Полученные результаты и алгоритмы могут быть использованы в интеллектуальных системах поддержки функционирования сложных многообъектных систем с целью высоконадежного прогнозирования отказов сложных многообъектных систем.

Благодарности

Работа выполнена при поддержке РФФИ, проект № 19-47-340010_p_a.

ЛИТЕРАТУРА

1. Сай Ван Квонг, Щербаков М. В. Метод прогнозирования остаточного ресурса на основе обработки данных многообъектных сложных систем. *Прикаспийский журнал: управление и высокие технологии*. 2019;(1):33-44.
2. Сай Ван Квонг, Щербаков М. В. Прогнозирование отказов сложных многообъектных систем на основе комбинации нейросетей: пути повышения точности прогнозирования. *Прикаспийский журнал: управление и высокие технологии*. 2020;(1):49-60.
3. Сай Ван Квонг. Глубокие нейронные сети для предсказательного технического обслуживания. *Моделирование, оптимизация и информационные технологии : научный сетевой журнал*. 2019;4(27):11.

4. Yan, M., Wang, X., Wang, B., Chang, M., Muhammad, I. Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model. *ISA transactions*. 2019.
5. Chen, Z., Cao, S., Mao, Z. Remaining useful life estimation of aircraft engines using a modified similarity and supporting vector machine (SVM) approach. *Energies*. 2018;11(1):28.
6. Patil, S., Patil, A., Handikherkar, V., Desai, S., Phalle, V. M., Kazi, F. S. Remaining Useful Life (RUL) Prediction of Rolling Element Bearing Using Random Forest and Gradient Boosting Technique. In *ASME 2018 International Mechanical Engineering Congress and Exposition. American Society of Mechanical Engineers Digital Collection*. 2018.
7. Li, X., Ding, Q., Sun, J. Q. Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering & System Safety*. 2018;172:1-11.
8. Zheng, S., Ristovski, K., Farahat, A., Gupta, C.: Long Short-Term Memory Network for Remaining Useful Life estimation. In *Proceedings of the 2017 IEEE In-ternational Conference on Prognostics and Health Management (ICPHM)*. Dallas, TX, USA, 19–21 June, 88-95 (2017).
9. Python. Режим доступа: <https://www.python.org/> свободный. – Заглавие с экрана. – Яз. англ. (дата обращения 25.02.2020).
10. Keras. Режим доступа: <https://keras.io>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения 30.02.2020).
11. TensorFlow. Режим доступа: <https://www.tensorflow.org/>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения 30.02.2020).
12. Keras Tuner. Режим доступа: <https://keras-team.github.io/keras-tuner/>. – Заглавие с экрана. – Яз. англ. (дата обращения 15.02.2020).

REFERENCES

1. Sai Van Cuong, Shcherbakov M. V. A data-driven method for remaining useful life prediction of multiple-component systems. *Caspian journal: management and high technologies*. 2019;(1):33-44.
2. Sai Van Cuong, Shcherbakov M. V. Failure prediction of complex multiple-component systems based on a combination of neural networks: ways to improve the accuracy of forecasting. *Caspian journal: management and high technologies*. 2020;(1):16.
3. Sai Van Cuong. Deep neural networks for predictive maintenance. *Modeling, Optimization and Information Technology*. 2019;4 (27):11.
4. Yan, M., Wang, X., Wang, B., Chang, M., Muhammad, I. Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model. *ISA transactions*. 2019.
5. Chen, Z., Cao, S., Mao, Z. Remaining useful life estimation of aircraft engines using a modified similarity and supporting vector machine (SVM) approach. *Energies*. 2018;11(1):28.
6. Patil, S., Patil, A., Handikherkar, V., Desai, S., Phalle, V. M., Kazi, F. S. Remaining Useful Life (RUL) Prediction of Rolling Element Bearing Using Random Forest and Gradient Boosting Technique. In *ASME 2018 International Mechanical Engineering Congress and Exposition. American Society of Mechanical Engineers Digital Collection*. 2018.
7. Li, X., Ding, Q., Sun, J. Q. Remaining useful life estimation in prognostics using deep convolution neural networks. *Reliability Engineering & System Safety*. 2018;172:1-11.
8. Zheng, S., Ristovski, K., Farahat, A., Gupta, C.: Long Short-Term Memory Net-work for Remaining Useful Life estimation. In *Proceedings of the 2017 IEEE In-ternational Conference on Prognostics and Health Management (ICPHM)*, Dallas, TX, USA, 19–21 June, 88-95 (2017)
9. Python. Available at: <https://www.python.org/> свободный. (accessed 25.02.2020).
10. Keras. Available at: <https://keras.io>, свободный. (accessed 30.02.2020).
11. TensorFlow. Availabe at: <https://www.tensorflow.org/>. (accessed 30.02.2020).
12. Keras Tuner. Available at: <https://keras-team.github.io/keras-tuner/> (accessed 15.02.2020).

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Сай Ван Квонг, аспирант, кафедра «Системы автоматизированного проектирования и поискового конструирования», ФГБОУ ВО Волгоградский государственный технический университет, Волгоград, Российская Федерация.
e-mail: svcuonghvktqs@gmail.com

Cuong V. S, PhD Student, CAD Department, Federal State Budgetary Educational Institution of Higher Education Volgograd State Technical University, Volgograd, Russian Federation

Щербаков Максим Владимирович, д-р. тех. наук, заведующий кафедрой «Системы автоматизированного проектирования и поискового конструирования», ФГБОУ ВО Волгоградский государственный технический университет, Волгоград, Российская Федерация
e-mail: maxim.shcherbakov@gmail.com

Maxim V. Shcherbakov, Dr. Sci., Head of CAD Department, Federal State Budgetary Educational Institution of Higher Education Volgograd State Technical University, Volgograd, Russian Federation