

DOI 10.21672/2074-1707.2020.49.4.049-060  
УДК 004.02

## ПРОГНОЗИРОВАНИЕ ОТКАЗОВ СЛОЖНЫХ МНОГООБЪЕКТНЫХ СИСТЕМ НА ОСНОВЕ КОМБИНАЦИИ НЕЙРОСЕТЕЙ: ПУТИ ПОВЫШЕНИЯ ТОЧНОСТИ ПРОГНОЗИРОВАНИЯ<sup>1</sup>

Статья поступила в редакцию 05.03.2020, в окончательном варианте – 11.03.2020.

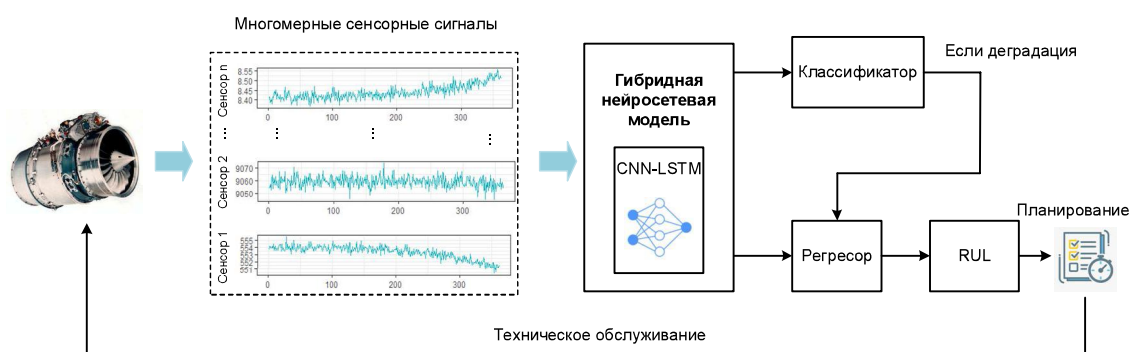
**Сай Ван Квонг**, Волгоградский государственный технический университет, 400005, Российская Федерация, г. Волгоград, пр. Ленина, 28,  
аспирант, e-mail: svcuonghvtqs@gmail.com

**Щербakov Максим Владимирович**, Волгоградский государственный технический университет, 400005, Российская Федерация, г. Волгоград, пр. Ленина, 28,  
доктор технических наук, профессор, e-mail: maxim.shcherbakov@vstu.ru

Для прогнозирования отказов сложных многообъектных систем в работе предложена гибридная нейросетевая модель с двумя выходами на основе сверточных нейронных сетей (*convolutional neural network, CNN*) и сетей долгой краткосрочной памяти (*long short-term memory; LSTM*). Сети CNN используются для извлечения пространственных свойств из многомерных сенсорных данных, а сети LSTM – для темпорального моделирования долговременных зависимостей. Первый выход предложенной модели является классификатором, позволяющим предсказать отказ системы в следующих *n*-шагах. Другими словами, он является идентификатором стадии деградации оборудования. Второй выход является регрессором, позволяющим оценить величину остаточного ресурса (*remaining useful life, RUL*) оборудования. Представлены результаты вычислительных экспериментов, подтверждающие высокую эффективность предложенного решения.

**Ключевые слова:** предсказательное обслуживание, остаточный ресурс, глубокие нейронные сети, ансамблевые методы, гиперпараметрическая оптимизация

### Графическая аннотация (Graphical annotation)



## FAILURE PREDICTION OF COMPLEX MULTIPLE-COMPONENT SYSTEMS BASED ON A COMBINATION OF NEURAL NETWORKS: WAYS TO IMPROVE THE ACCURACY OF FORECASTING

The article was received by the editorial board on 05.03.202006, in the final version – 11.03.2020.

**Sai Van Cuong**, Volgograd State Technical University, 28 Lenin Ave., Volgograd, 400005, Russian Federation,  
post-graduate student, e-mail: svcuonghvtqs@gmail.com

**Shcherbakov Maksim V.**, Volgograd State Technical University, 28 Lenin Ave., Volgograd, 400005, Russian Federation,  
Doct. Sci. (Engineering), Professor, e-mail: maxim.shcherbakov@gmail.com

The paper proposes a hybrid neural network model with two outputs based on convolutional neural networks (CNN) and long short-term memory networks (LSTM) for predicting failures of complex multi-component systems. CNN networks are used to extract spatial properties from multidimensional sensor data, and LSTM networks are used for temporal modeling of long-term dependencies. The first output of the proposed model is a classifier that allows

<sup>1</sup> Работа выполнена при поддержке РФФИ, проект № 19-47-340010\_p\_a.

you to predict whether the system may fail in the next  $n$ -steps of time in the future, in other words, it is an identifier of the stage of degradation of the equipment. The second output is a regressor that allows to predict the number of the remaining useful life (RUL) of the equipment at each time step. The results of computational experiments confirming the high efficiency of the proposed solution are presented.

**Key words:** predictive maintenance, remaining useful life (RUL), deep neural network, ensemble method, hyperparameter optimization

**Введение.** В современных экономических условиях обеспечение технического обслуживания и ремонта (ТОиР) оборудования на промышленных предприятиях [2], на транспорте, в высокотехнологичных медицинских организациях [1] и пр. играет важнейшую роль. Одним из основных факторов, оказывающих влияние на рентабельность деятельности предприятий в различных отраслях промышленности, являются простои и отказы оборудования, сопровождающиеся большими производственными потерями. Это сказывается на повышении себестоимости производства продукции и снижает конкурентоспособность предприятий, работающих в различных предметных областях. Аналогично для медицинских организаций простои медоборудования ухудшают «доступность и качество» медицинской помощи и, как следствие, конкурентоспособность на рынке оказания медицинских услуг.

Обеспечение надежного функционирования оборудования на этапе эксплуатации с минимальными затратами является актуальной задачей для различных производств/организаций с учетом следующих факторов: 1) быстрого роста сложности систем; 2) возрастающих рисков, связанных с простоями оборудования; 3) ужесточения условий к выполнению требований техники безопасности на производстве и охране окружающей среды.

В последнее время в рамках внедрения концепции «Индустрия 4.0» в области организации ТОиР сложной техники значительный интерес вызывают подходы, основанные на использовании передовых методов анализа больших массивов данных на базе использования инновационных технологий искусственного интеллекта. В основном речь идет о концепции предсказательного технического обслуживания (*predictive maintenance (PdM)*), а именно о создании предсказательных моделей для предотвращения отказов оборудования. Под прогнозированием отказа здесь понимается оценка длительности временного интервала, по истечении которого произойдет отказ оборудования. Этот интервал получил название «остаточный срок полезного использования» или «остаточный ресурс» (*remaining useful life (RUL)*). Достоверная оценка RUL и вероятности наступления отказа оборудования является основанием для принятия оптимального решения при выборе стратегии воздействия на оборудование [3]. 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 рамках техник *PdM* исторически изучаются различные подходы к моделированию процесса деградации оборудования для оценки RUL: а) подходы, основанные на физической модели деградации (*physical model-based methodology (MBM)*); б) подходы, основанные на использовании формализованных знаний (*knowledge-based methodology (KBM)*); в) подходы, основанные на обработке и анализе данных (*data-driven methodology (DDM)*). Тенденции последних лет доказывают, что именно DDM обладает наибольшим потенциалом и практической эффективностью, которая продолжает наращиваться на основе использования как статистических методов анализа многомерных данных, так и методов машинного обучения. Статистические подходы включают винеровский процесс [13] и методы стохастической фильтрации [5]. Среди методов машинного обучения наибольшее распространение получили такие методы, как метод опорных векторов (*support vector machine (SVM)*) [8], метод случайного леса (*random forest (RF)*) и градиентный бустинг (*gradient boosting (GB)*) [9]. В последнее время методы глубокого машинного обучения показали отличную производительность при прогнозировании RUL. Здесь отметим сверточные нейронные сети (*Convolutional neural network (CNN)*) [10] и рекуррентные нейронные сети (*recurrent neural network (RNN)*) [6, 7]. Одна из причин успешного применения глубоких нейронных сетей заключается в том, что они автоматически выделяют из данных важные признаки, необходимые для решения задачи [4]. В работе [3] предложенный нами гибридный метод на основе сетей CNN и LSTM дал превосходный результат по сравнению с альтернативными методами при прогнозировании остаточного ресурса авиационных газотурбинных двигателей.

Настоящая работа посвящена совершенствованию архитектуры предложенной нами гибридной модели, оптимизации гиперпараметров и преобразованию целевой переменной RUL для получения более высокой точности при прогнозировании отказов сложных многообъектных систем.

**Постановка задачи.** Пусть эксплуатируется некоторый парк однотипного оборудования типа  $\beta$ . Условно будем называть такой парк оборудования парком оборудования и обозначать его как  $D^\beta$ .

Пусть каждая единица оборудования в парке  $id \in D^\beta$ ,  $id = 1, \dots, m$  оснащена сенсорной сетью, состоящей из  $n$  сенсоров  $s_i^{(id)}$ ,  $i = 1, \dots, n_s$ , при этом сенсоры являются источниками информации о состоянии узлов и агрегатов оборудования и об условиях его эксплуатации. Тогда парк однотипного оборудования  $D^\beta$  представляется на основе сенсорных данных в следующем виде:

$$D^\beta = \langle id, \{s_i^{(id)}\}_{i=1}^{n_s}, \{r_i^{(id)}(T^{(id)})\}_{i=1}^{n_s} \rangle,$$

где  $id$  – уникальный идентификатор оборудования,  $\{s_i^{(id)}\}_{i=1}^{n_s}$  – множество сенсоров для оборудования  $id \in D^\beta | id = 1, \dots, m$ ,  $r_i^{(id)}(T^{(id)})$  – данные, поступившие от сенсора  $s_i^{(id)}$  для множества моментов измерения  $T^{(id)} = t_1^{(id)}, t_2^{(id)}, \dots, t_{T^{(id)}}^{(id)}$ , будем называть траекторией  $i$ -го сенсора для  $-$ го экземпляра оборудования  $id \in D^\beta$ . Тогда данные, поступившие от  $n_s$  сенсоров для единицы  $id \in D^\beta$ , представляют собой многомерные временные ряды  $R^{(id)}$ :

$$R^{(id)} = \begin{pmatrix} r_1^{(id)}(t_1^{(id)}) & \dots & r_{n_s}^{(id)}(t_1^{(id)}) \\ \vdots & \ddots & \vdots \\ r_1^{(id)}(t_{T^{(id)}}^{(id)}) & \dots & r_{n_s}^{(id)}(t_{T^{(id)}}^{(id)}) \end{pmatrix}.$$

Рассмотрим ситуацию, когда имеется конечное множество  $D_q^\beta \subseteq D^\beta$ , состоящее из  $q$  единиц оборудования типа  $\beta$ , для которых массив показаний сенсоров  $R_q(T(D_q^\beta)) = \{r_i^{(id)}(T^{(id)}) | id = 1, \dots, q, \forall id : id \in D_q^\beta, i = 1, \dots, n_s\}$ , состоящий из прошедших наблюдение траекторий  $r_i^{(id)}$ , каждая из которых заканчивается выходом из строя, соответствующего экземпляра  $id \in D_q^\beta$ . Другими словами, в момент времени  $t_{r^{(id)}}^{(id)}$  оборудование  $id \in D_q^\beta$  выходит из строя.

При изучении прошедших сенсорных данных из  $q$  единиц оборудования из множества  $D_q^\beta$  требуется построить эффективную модель, которая позволяет предсказать в момент времени « $t$ », выйдет ли оборудование типа  $\beta$  из строя в ближайшем будущем с приемлемой точностью. Эта задача может быть сформулирована в виде одного из двух подходов. Первый подход предсказывает, существует ли вероятность отказа в следующих  $n$ -шагах по времени. Второй подход предсказывает, сколько времени осталось до следующего отказа (остаточный ресурс, RUL).

**Создание целевой переменной RUL для обучения моделей.** Для  $q$  единиц оборудования из множества  $D_q^\beta$  RUL представляет собой линейную функцию затухания и вычисляется по формуле  $RUL = T^{(id)} - t^{(id)}$ , где  $T^{(id)}$  – время, на котором произошёл отказ для оборудования  $id$ , а  $t^{(id)}$  – текущее время наблюдения за его работой (рис. 1).




Рисунок 1 – Иллюстрация к изменению состояния оборудования и наступления отказа

Однако в начале, когда оборудование работает в совершенно «здоровом» состоянии, его состояние не может быть принято как деградирующее (рис. 2). Поэтому данные мониторинга перед тем, как оборудование начинает быстро деградировать, не следует использовать для обучения модели, потому что это может привести к тому, что модель будет ошибаться при оценке RUL. Для этого целевая переменная RUL преобразуется в виде кусочно-линейной функции следующим образом:

$$RUL(t) = \begin{cases} RUL_c & \text{для } 0 \leq t \leq T_d \\ T - t & \text{для } T_d \leq t \leq T \end{cases}$$

где  $T_d$  – момент времени начала деградация (рис. 3);  $RUL_c$  – постоянная величина RUL. Кусочно-линейная функция RUL затем используется в качестве цели для обучения алгоритмов.




Рисунок 2 – Пример данных, полученных из двух сенсоров на двух экземплярах однотипного оборудования

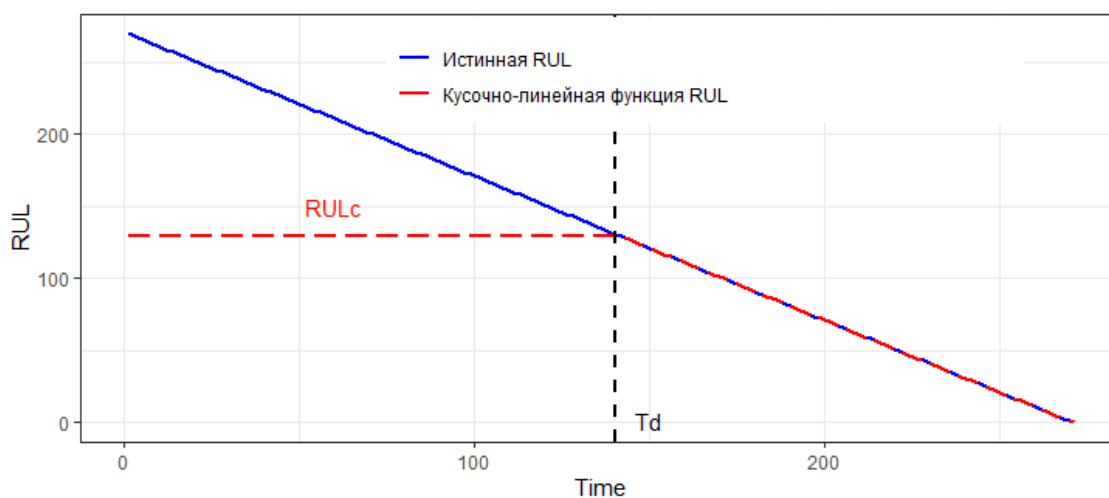


Рисунок 3 – Кусочно-линейная функция RUL

**Предложенная гибридная модель CNN-LSTM.** Архитектура предложенной гибридной модели CNN-LSTM представлена на рисунке 4.

Предложенная модель состоит из двух основных компонентов: а) сети 1D CNN для извлечения нужных признаков; б) сети LSTM для темпорального моделирования долговременных зависимостей признаков. Модель включает полностью связанную нейронную сеть для формирования двух выходов: 1-й предсказывает, существует ли вероятность отказа на следующих  $n$ -шагах по времени – задача классификации; 2-й предсказывает, сколько времени осталось до следующего отказа (остаточный ресурс, RUL) – задача регрессии.

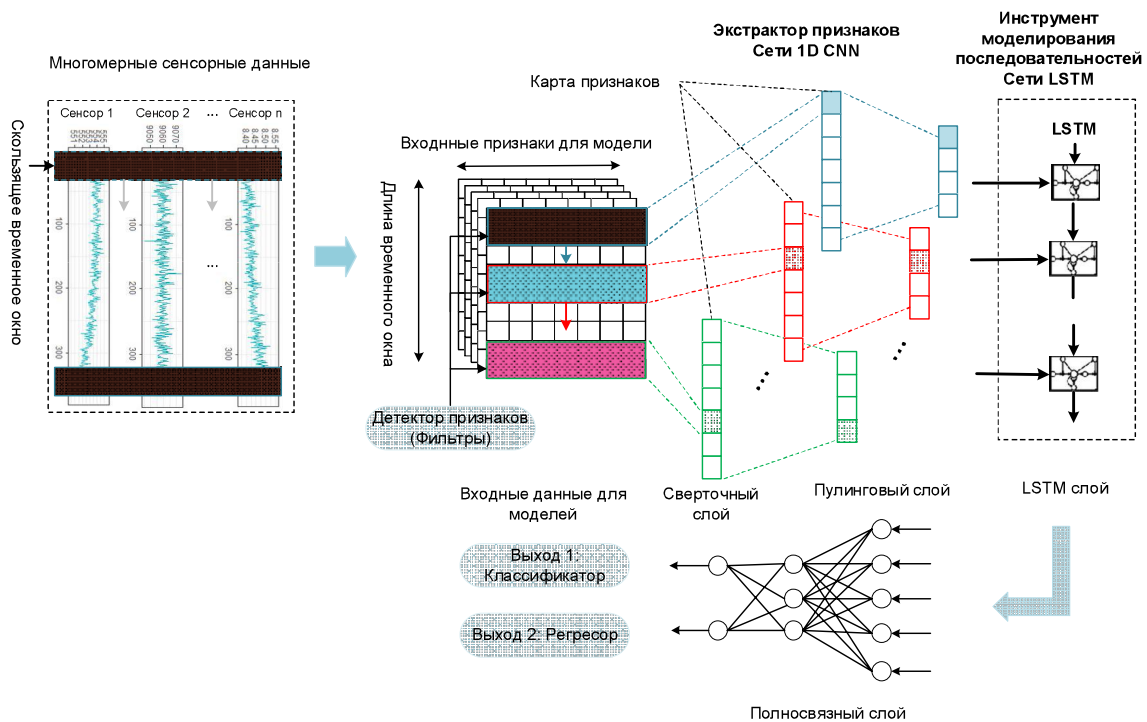


Рисунок 4 – Архитектура предложенной гибридной модели CNN-LSTM

Первый выход дает только логический ответ, но может обеспечить высокую точность при меньшем количестве данных. Второй выход предоставляет больше информации о том, когда произойдет отказ. Главным недостатком второго выхода является то, что он даёт более точный ответ тогда, когда остаточный ресурс оборудования ближе к нулю, то есть когда оборудование находится на стадии деградации. Однако на практике мы не знаем, когда оборудование находится на этой стадии. Следовательно, не можем оценить, насколько точен ответ, который дает второй выход для принятия оптимального решения. И в этом контексте важную играет первый выход как идентификатор стадии деградации оборудования.

Свёрточные нейронные сети (*convolutional neural network (CNN)*) являются лучшим инструментом машинного обучения для обработки изображений и видео. Основная причина успеха в этом случае определяется высокой способностью CNN по извлечению локальной информации из больших данных путем «скольжения» сверточных фильтров по двумерным входным данным. В таких задачах используются так называемые двумерные сверточные нейронные сети (2D CNN), так как они извлекают двумерные шаблоны из изображений и применяют идентичные преобразования к каждому такому шаблону. Аналогично можно использовать одномерные свертки для извлечения одномерных шаблонов (подпоследовательностей) из данных с сенсоров в виде последовательности. Рисунок 5 отражает разницу между 1D CNN и 2D CNN.




Рисунок 5 – Разница между 1D CNN и 2D CNN

*Сету LSTM* – особая разновидность архитектуры рекуррентных нейронных сетей (recurrent neural networks, RNN), разработанная Хохрейтером и Шмидхубером в 1997 г. LSTM имеют цепную структуру повторяющихся модулей (repeating module) нейронной сети, как и стандартные RNN. Однако повторяющиеся модули в LSTM имеют более сложную структуру (рис. 6а) по сравнению с стандартными RNN. Благодаря этой структуре LSTM способны запоминать информацию в течение длительных периодов времени. По этой причине LSTM являются мощным инструментом для моделирования данных последовательности, в частности сенсорных данных в виде многомерных временных рядов. Рисунок 6б иллюстрирует применение сетей LSTM для моделирования данных многомерных временных рядов.

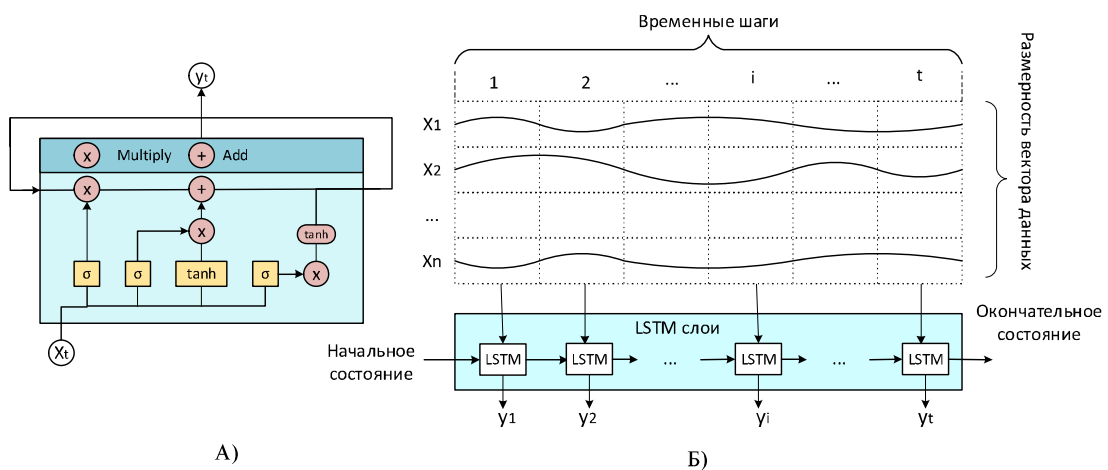


Рисунок 6 – LSTM для моделирования данных многомерных временных рядов

Алгоритм обучения предложенной гибридной модели CNN-LSTM показан на рисунке 7.

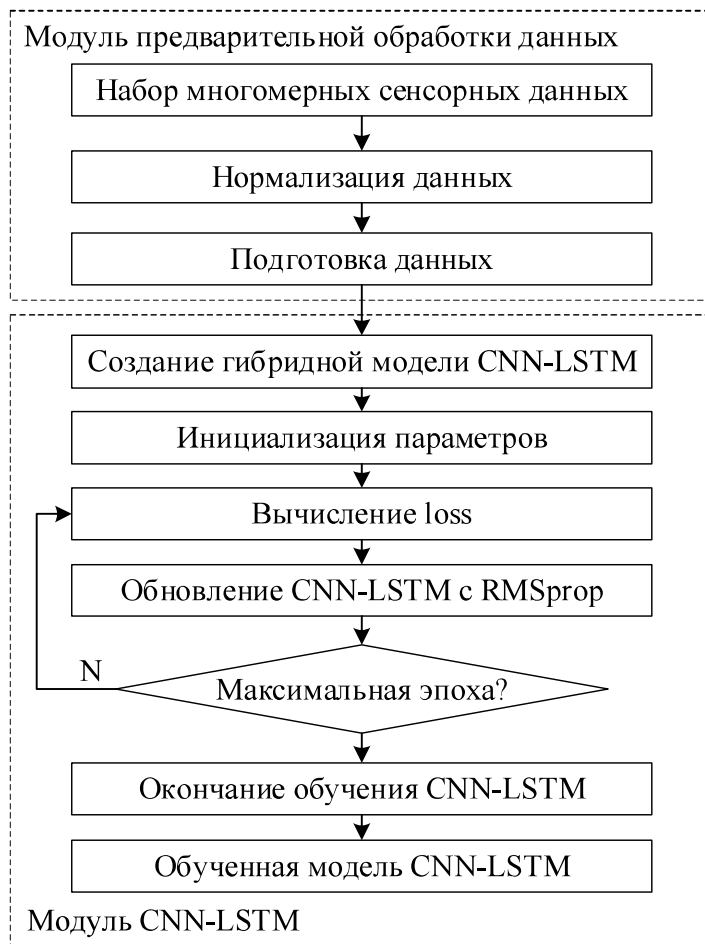


Рисунок 7 – Алгоритм обучения гибридной модели CNN-LSTM

**Результаты и обсуждение.** Для обоснования эффективности предложенной модели были проведены вычислительные эксперименты, реализация которых осуществлялась с помощью программы, написанной на языке Python. Нейросетевые модели были реализованы с использованием модульной библиотеки Keras [14], функционирующей поверх библиотек TensorFlow от Google [16].

Для проведения экспериментов был использован набор данных FD001 из широко известной базы данных C-MAPPS Dataset (NASA) [11], который содержит показания сенсоров в полете, имитирующих поведение однотипных авиационных газотурбинных двигателей и условия их работы. Этот набор включает в себя две выборки: обучающую выборку *train\_FD001.txt* и тестовую выборку *test\_FD001.txt*. 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.

**Подготовка данных для обучения сетей.** Процесс подготовки данных для обучения моделей целесообразно представить в виде следующей последовательности шагов.

**Шаг 1.** Выбор признаков. Многомерные сенсорные данные в наборе FD001 содержат показания от 24 сенсоров. Однако при анализе и визуализации данных было обнаружено, что некоторые сенсоры имеют постоянные значения во времени. Поэтому следует исключить эти сенсорные показания из набора данных, так как они не дают ценной информации. В результате получается набор данных от 17 сенсоров.

**Шаг 2.** Нормализация данных. Следует отметить, что значения, полученные от разных сенсоров, имеют величины, относящиеся к самым разным диапазонам (рис. 2). Нейронные сети, конечно, смогут автоматически адаптироваться к таким разнородным данным, однако это усложнит их обучение и может негативно повлиять на качество результатов обучения. 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.** Создание кусочно-линейной функции RUL для обучающей выборки (как описано в предыдущем разделе).

**Шаг 4.** Создание меток для задачи классификации. Набор данных помечается двумя классами в соответствии со значением величины RUL. Для временных шагов, где значение RUL  $\geq 40$ , помечается «классом 0», а там, где RUL  $< 40$ , помечается как «класс 1».

**Шаг 5.** Подготовка данных для обучения сетей. Нейронные сети будут принимать в качестве входных данных последовательность значений. В данном случае в качестве входных данных использована матрица, состоящая из 17 признаков и фиксированного скользящего окна длиной  $L = 30$ . В результате были получены трехмерные тензоры с формой (образцы, метки\_времени, признаки).

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

**Оптимизация гиперпараметров нейросети с помощью фреймворка Keras-Tuner.** Для выбора набора оптимальных гиперпараметров для обучающих сетей применялся приём случайного поиска с использованием фреймворка Keras-Tuner [15]. Keras-Tuner – это фреймворк для оптимизации гиперпараметров для моделей Keras, созданный Google. В данном случае выполняется поиск комбинации следующих гиперпараметров: количество нейронов в каждом слое; функции активации, которые используются в слоях; тип оптимизатора при обучении нейронной сети. Процедура оптимизации гиперпараметров для нейросетевых моделей представлена на рисунке 8.




Рисунок 8 – Процедура оптимизации гиперпараметров для нейросетевых моделей

Результат в виде оптимальных гиперпараметров для предложенной модели показан в таблице 1.

Таблица 1 – Набор полученных оптимальных гиперпараметров для предложенной модели

№	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	70	-	–	–	0,2
5	Dense	80	-	–	–	–
6	Dense (Классификатор)	1	-	–	sigmoid	–
7	Dense (Перцептор)	1	-	–	linear	–

На рисунке 9 представлены графики изменения значений функции ошибки по эпохе при обучении предложенной модели с использованием полученных оптимальных гиперпараметров.



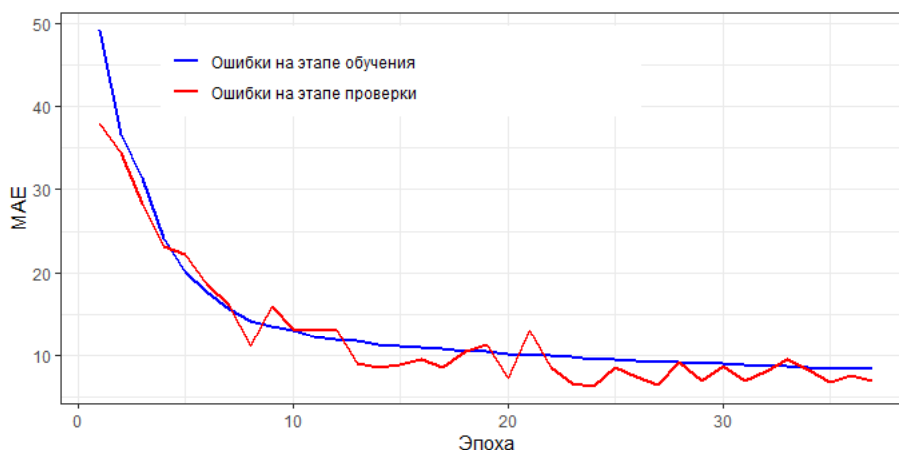


Рисунок 9 – Графики изменения значений функции ошибки по эпохе при обучении

**Метрики оценки качества моделей.** В данной работе для оценки точности регрессора используются средняя абсолютная ошибка (mean absolute error (MAE)), средняя квадратичная ошибка (root mean square error (RMSE)) и средняя абсолютная процентная ошибка (mean absolute percentage error (MAPE)). Они рассчитываются по формулам:

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| = \text{mean}_{(i=1:n)}(|e_i|),$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (e_i^2)} = \sqrt{\text{mean}_{i=1:n}(e_i^2)},$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n 100 \cdot \frac{|e_i|}{y_i} = \text{mean}_{i=1:n}(100 \cdot \frac{e_i}{y_i}),$$

где  $e_i = (y_i - \hat{y}_i)$ ,  $\hat{y}_i$  и  $y_i$  – прогнозные и истинные значения RUL для двигателя  $i$  соответственно.

Для оценки точности классификатора используется доля правильно классифицированных объектов (accuracy), точность (precision) и полнота (recall):

$accuracy = \frac{TP+TN}{TP+TN+FP+FN}$ , по сути, это вероятность того, что класс будет предсказан правильно;

$precision = \frac{TP}{TP+FP}$  показывает, какую долю объектов, распознанных как объекты положительного класса, мы предсказали верно;

$recall = \frac{TP}{TP+FN}$  показывает, какую долю объектов, реально относящихся к положительному классу, мы предсказали верно,

где  $TP, TN, FP, FN$  – значения матрицы ошибок бинарной классификации (табл. 2).

Таблица 2 – Матрица ошибок бинарной классификации

	$y = 1$	$y = 0$
$\hat{y} = 1$	True Positive (TP)	False Positive (FP)
$\hat{y} = 0$	False Negative (FN)	True Negative (TN)

*Примечание.*  $\hat{y}$  – это ответ алгоритма на объекте;  $y$  – истинная метка класса на этом объекте. TP – истинно-положительное решение; TN – истинно-отрицательное решение; FP – ложно-положительное решение (ошибка типа 1); FN – ложно-отрицательное решение (ошибка типа 2).

На рисунке 10 представлено сравнение прогнозных значений RUL и истинных значений RUL на двигателе  $id = 2$  в обучающей выборке для линейной целевой функции RUL и кусочно-линейной целевой функции.




Рисунок 10 – Сравнение прогнозных значений RUL и истинных значений RUL на двигателе id = 2 в обучающей выборке: а) для линейной целевой функции RUL; б) для кусочно-линейной целевой функции RUL

RMSE, по тестовым данным полученной сети, составило 12,478. Для сравнения RMSE, по тестовым данным для предложенной нами гибридной модели в работе [3], составило 15,076. Таким образом, точность предлагаемого алгоритма повысилась на 17 %.

Таблица 3 показывает сравнение результатов, полученных для предложенной модели с результатами других исследований применительно к решению рассматриваемой задачи.

Таблица 3 – Сравнение результатов, полученных для предложенной модели с другими исследованиями

Название модели	RMSE	Год публикации
SVM [7]	29,82	2013
CNN [9]	18,45	2016
LSTM [5]	17,84	2017
Глубокие LSTM [6]	16,74	2018
DenseStacking Ensemble [11]	16,67	2019
Предложенная CNN-LSTM-модель	<b>12,48</b>	–

На рисунке 11 представлена визуализация реальных значений RUL и прогнозных значений RUL, полученных с помощью предложенной модели.

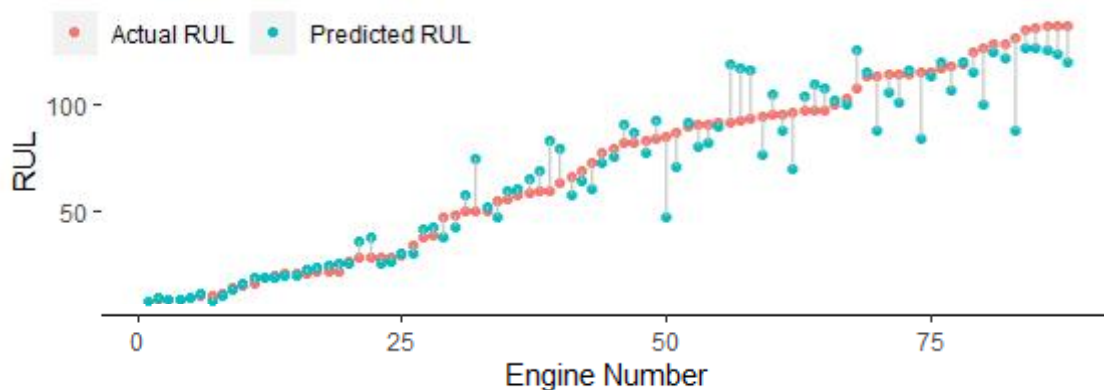


Рисунок 11 – Результаты прогнозирования RUL тестовых двигателей (по возрастанию RUL)

Следует отметить, что при возрастании величины RUL точность прогнозирования уменьшается. Другими словами, модель даёт более точные прогнозы, когда двигатель находится ближе к моменту отказа. Это подтверждается результатами, показанными в таблице 4. Она содержит результаты ошибки прогнозирования, полученные с помощью предложенной модели для прогнозирования остаточного ресурса на двигателях в тестовом наборе по различным группам.

Таблица 4 – Ошибки прогнозирования RUL предложенной модели на различных группах двигателей

Ошибка прогнозирования	Группа 1 ( $RUL \leq 40$ )	Группа 2 ( $40 < RUL \leq 80$ )	Группа 3 ( $RUL \geq 80$ )	Для всех двигателей
MAE	2,043977	9,047644	12,61425	8,561976
RMSE	3,024680	11,13613	16,23768	<b>12,47810</b>
MAPE	9,323707	15,74691	12,10987	11,92597

Точности классификации для предложенной гибридной модели на тестовых двигателях показаны в таблице 5.

Таблица 5 – Результаты для точности классификации состояний оборудования на данных по тестовым двигателям

	Accuracy	Precision	Recall
Классификатор CNN-LSTM	99 %	100 %	98,7 %

**Заключение.** Результаты моделирования показывают, что предложенная гибридная нейросетевая модель CNN-LSTM с двумя выходами, основанная на использовании сверточной нейронной сети (CNN) и сети долгой краткосрочной памяти (LSTM), превосходит аналоги при тестировании на базе данных C-MAPPS. Полученные результаты и алгоритмы могут быть использованы в системах превентивного обслуживания оборудования с целью высоконадежной идентификации стадии его деградации и прогнозирования отказов сложных многообъектных систем.

#### Библиографический список

1. Брумштейн Ю. М. Управление парком оборудования в российских медицинских учреждениях: технологии принятия и реализации решений, оценки их результативности / Ю. М. Брумштейн, Е. В. Пфандер // Прикаспийский журнал: управление и высокие технологии. – 2017. – № 4 (40). – С. 110–125. ([http://hi-tech.asu.edu.ru/files/4\(40\)/110-125.pdf](http://hi-tech.asu.edu.ru/files/4(40)/110-125.pdf))
2. Ерохин Е. А. Особенности организации служб технического обслуживания оборудования на предприятиях / Е. А. Ерохин // Экономинфо. – 2009. – № 12. – С. 11–13.
3. Сай Ван Квонг. Метод прогнозирования остаточного ресурса на основе обработки данных многообъектных сложных систем / Сай Ван Квонг, М. В. Щербаков // Прикаспийский журнал: управление и высокие технологии. – 2019. – № 1 (45). – С. 33–44. ([http://hi-tech.asu.edu.ru/files/1\(45\)/33-44.pdf](http://hi-tech.asu.edu.ru/files/1(45)/33-44.pdf))
4. Сай Ван Квонг. Глубокие нейронные сети для предсказательного технического обслуживания / Сай Ван Квонг // Моделирование, оптимизация и информационные технологии (МОИТ). – 2019. – Т. 7, № 4 (27). – 11 с. DOI: 10.26102/2310-6018/2019.27.4.011.
5. Cui L. A novel Switching Unscented Kalman Filter method for remaining useful life prediction of rolling bearing / L. Cui, X. Wang, Y. Xu, H. Jiang, J. Zhou // Measurement. – 2019. – № 135. – P. 678–684.
6. Dong D. Life prediction of jet engines based on LSTM-recurrent neural networks / D. Dong, X. Li, F. Sun // Prognostics and System Health Management Conference. – 2017. – P. 1–6.
7. Hsu C. S. Remaining useful life estimation using Long short-term memory deep learning / C. S. Hsu, J. R. Jiang // IEEE International Conference on Applied System Invention. – 2018. – P. 58–61.
8. Louen C. A new framework for remaining useful life estimation using Support Vector Machine classifier / C. Louen, S. X. Ding, C. Kandler // Conference on control and Fault-Tolerant Systems. – 2013. – P. 228–233.
9. Patil S. Remaining Useful Life (RUL) Prediction of Rolling Element Bearing Using Random Forest and Gradient Boosting Technique / S. Patil, A. Patil, V. Handikherkar, S. Desai, V. M. Phalle & F. S. Kazi // ASME 2018 International Mechanical Engineering Congress and Exposition. American Society of Mechanical Engineers Digital Collection. – 2018.
10. Sateesh Babu G. Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life / G. Sateesh Babu, P. Zhao, X. L. Li // International Conference on Database Systems for Advanced Applications. – 2016. – P. 214–228.
11. Saxena A., Goebel K. Turbofan Engine Degradation Simulation Data Set. – Режим доступа: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения: 14.08.2019).
12. Singh S. K. A novel soft computing method for engine RUL prediction / S. K. Singh, S. Kumar, J. P. Dwivedi // Multimed. Tools Appl. – 2019 – № 78. – P. 4065–4087.
13. Zhang Z. Degradation data analysis and remaining useful life estimation: A review on Wiener-process-based methods / Z. Zhang, X. Si, C. Hu, Y. Lei // Eur. J. Oper. Res. – 2018. – № 271. – P. 775–796.
14. Keras: The Python Deep Learning library. – Режим доступа: <https://keras.io/>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения: 12.12.2019).
15. Keras Tuner. – Режим доступа: <https://keras-team.github.io/keras-tuner/>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения: 15.01.2020).
16. Tensorflow. – Режим доступа: <https://www.tensorflow.org/>, свободный. – Заглавие с экрана. – Яз. англ. (дата обращения: 08.12.2019).

#### References

1. Brumshteyn Yu. M., Pfander E.V. Upravlenie parkom oborudovaniya v rossiyskikh meditsinskikh uchrezhdeniyakh: tekhnologii prinyatiya i realizatsii resheniy, otsenki ikh rezultativnosti [Management of efficiency of operation of the park of the medical equipment in stationary medical institutions: the system analysis of the purposes, methods of acceptance and implementation of decisions, criteria for evaluation of the achieved results].

*Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian Journal: Control and High Technologies], 2017, no. 4 (40), pp. 110–125. ([http://hi-tech.asu.edu.ru/files/4\(40\)/110-125.pdf](http://hi-tech.asu.edu.ru/files/4(40)/110-125.pdf))

2. Erokhin E. A. Osobennosti organizatsii sluzhb tekhnicheskogo osbluzhivaniya oborudovaniya na predpriyatiyakh [Characteristics of organization of equipment maintenance services at enterprises]. *Ekonominfo* [Econominfo], 2009, no. 12, pp. 11–13.

3. Say Van Kvang, Shcherbakov M. V. Metod prognozirovaniya ostatochnogo resursa na osnove obrabotki dannykh mnogoobektnykh slozhnykh system [A data-driven method for remaining useful life Prediction of multiple-component systems]. *Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian Journal: Control and High Technologies], 2019, no. 1 (45), pp. 33–44. ([http://hi-tech.asu.edu.ru/files/1\(45\)/33-44.pdf](http://hi-tech.asu.edu.ru/files/1(45)/33-44.pdf))

4. Say Van Kvang. Glubokie neyronnye seti dlya predskazatel'nogo tekhnicheskogo obsluzhivaniya [Deep neural networks for predictive maintenance]. *Modelirovanie, optimizatsiya i informatsionnye tekhnologii (MOIT)* [Modeling, optimization and information technology], 2019, vol. 7, no. 4 (27). 11. p. DOI: 10.26102/2310-6018/2019.27.4.011.

5. Cui L., Wang X., Xu Y., Jiang H., Zhou J. A novel Switching Unscented Kalman Filter method for remaining useful life prediction of rolling bearing. *Measurement*, 2019, no. 135, pp. 678–684.

6. Dong D., Li X., Sun F. Life prediction of jet engines based on LSTM-recurrent neural networks. *Prognostics and System Health Management Conference*, 2017, pp. 1–6.

7. Hsu C. S., Jiang J. R., Remaining useful life estimation using long short-term memory deep learning. *IEEE International Conference on Applied System Invention*, 2018, pp. 58–61.

8. Louen C., Ding S. X., Kandler C. A new framework for remaining useful life estimation using Support Vector Machine classifier. *Conference on control and Fault-Tolerant Systems*, 2013, pp. 228–233.

9. Patil S., Patil A., Handikherkar V., Desa S., Phalle V. M. & Kazi F. S. Remaining Useful Life (RUL) Prediction of Rolling Element Bearing Using Random Forest and Gradient Boosting Technique. *ASME 2018 International Mechanical Engineering Congress and Exposition. American Society of Mechanical Engineers Digital Collection*, 2018.

10. Sateesh Babu G., Zhao P., Li, X. L. Deep Convolutional Neural Network Based Regression Approach for Estimation of Remaining Useful Life. *International Conference on Database Systems for Advanced Applications*, 2016, pp. 214–228.

11. Saxena A., Goebel K. *Turbofan Engine Degradation Simulation Data Set*. Available at: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository> (accessed 14.08.2019).

12. Singh S. K., Kumar S., Dwivedi J. P. A novel soft computing method for engine RUL prediction. *Multimed. Tools Appl.*, 2019, no. 78, pp. 4065–4087.

13. Zhang Z., Si X., Hu C., Lei Y., Degradation data analysis and remaining useful life estimation: A review on Wiener-process-based methods. *Eur. J. Oper. Res.*, 2018, no. 271, pp. 775–796.

14. *Keras: The Python Deep Learning library*. Available at: <https://keras.io/> (accessed 12.12.2019).

15. *Keras Tuner*. Available at: <https://keras-team.github.io/keras-tuner/> (accessed 15.01.2020).

16. *Tensorflow*. Available at: <https://www.tensorflow.org/> (accessed 08.12.2019).