

## Прогнозирование неисправностей в технических системах на основе использования сверточной нейронной сети

Ю. А. Кораблев<sup>✉</sup>, Д. М. Лосева, М. Ю. Шестопалов

Санкт-Петербургский государственный электротехнический университет  
«ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

<sup>✉</sup>[juri.korablev@gmail.com](mailto:juri.korablev@gmail.com)

**Аннотация.** Показано, как прогнозировать остаточный срок службы (RUL) технических систем с помощью глубоких сверточных нейронных сетей (CNN). Преимущество подхода с глубоким обучением заключается в том, что в этом случае не нужно вручную извлекать или выбирать признаки для используемой модели для прогнозирования RUL. Кроме того, здесь не нужны предварительные знания о прогнозировании состояния машины или обработке сигналов для разработки модели прогнозирования RUL на основе глубокого обучения. Тестирование метода проводилось в демонстрационной программе MatLab, реализующей данный метод прогнозирования возникновения неисправностей в технических системах<sup>1</sup>. В программе были использованы Predictive Maintenance Toolbox и Deep Learning Toolbox среды MatLab.

**Ключевые слова:** неисправности, диагностика состояния технической системы, прогнозирование возникновения неисправностей, остаточный срок службы технического устройства, сверточные нейронные сети, обучение нейронной сети

**Для цитирования:** Кораблев Ю. А., Лосева Д. М., Шестопалов М. Ю. Прогнозирование неисправностей в технических системах на основе использования сверточной нейронной сети // Изв. СПбГЭТУ «ЛЭТИ». 2025. Т. 18, № 7. С. 69–74. doi: 10.32603/2071-8985-2025-18-7-69-74.

**Конфликт интересов.** Авторы заявляют об отсутствии конфликта интересов.

Original article

## Predicting Faults in Technical Systems Using Convolutional Neural Networks

Yu. A. Korablev<sup>✉</sup>, D. M. Loseva, M. Yu. Shestopalov

Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

<sup>✉</sup>[juri.korablev@gmail.com](mailto:juri.korablev@gmail.com)

**Abstract.** Demonstrates how to predict the remaining useful life (RUL) of technical systems using deep convolutional neural networks (CNN). The advantage of the deep learning approach is that it eliminates the need to manually extract or select features for the model used to predict the RUL. In addition, no prior knowledge of machine condition prediction or signal processing is needed to develop a deep learning-based RUL prediction model. The method was tested in a MatLab demo program implementing this method for predicting the occurrence of faults in technical systems<sup>1</sup>. The program used the Predictive Maintenance Toolbox and Deep Learning Toolbox of the MatLab environment.

**Keywords:** faults, diagnostics of the state of a technical system, prediction of the occurrence of faults, residual service life of a technical device, convolutional neural networks, training of a neural network

**For citation:** Korablev Yu. A., Loseva D. M., Shestopalov M. Yu. Predicting Faults in Technical Systems Using Convolutional Neural Networks // LETI Transactions on Electrical Engineering & Computer Science. 2025. Vol. 18, no. 7. P. 69–74. doi: 10.32603/2071-8985-2025-18-7-69-74.

**Conflict of interest.** The authors declare no conflicts of interest.

<sup>1</sup> <https://www.mathworks.com/help/predmaint/ug/remaining-useful-life-estimation-using-convolutional-neural-network.html>.

**Введение.** В статье описывается процесс разработки системы диагностики на основе сверточной нейронной сети [1]–[3]. Название архитектуры сети получила из-за наличия в ней операции свертки, которая в общем случае на качественном уровне убирает лишнее и оставляет только важную информацию. Но по принципу действия она похожа на другие нейронные сети. Например, аналогично полносвязной нейронной сети сверточная в своем обучении использует алгоритм обратного распространения ошибки. Особенность этой нейронной сети состоит в выделении в процессе работы сначала картины в целом, затем – в переключении на отдельные детали, т. е. в случае диагностики оценивается сначала общее состояние, наличие неисправности в системе, а затем определяется правильный диагноз. Наиболее популярные архитектуры сверточных нейронных сетей – ResNet, XResNet, EfficientNet и др. Эта сеть – один из популярных инструментов методов машинного обучения, входит в состав технологий глубокого обучения. Методы машинного обучения успешно применяются в области мониторинга и диагностики состояния технических систем. В данном случае нейронная сеть предназначена для получения оценки RUL (Remaining Useful Life) [4]–[5], метода для обучения модели нейронной сети с помощью исторических данных и выполнения прогноза остающегося срока полезного использования, т. е. прогнозируется возникновение неисправностей в технической системе. В данной статье рассматривается проблема диагностики состояний турбовентиляторного двигателя, по сути решается задача классификации, распознавание входных данных и распределение их по классам, соответствующим нормальному режиму работы и различным неисправностям.

Построение системы диагностики происходит экспериментально. По результатам эксперимента реализуется обучение сверточной нейронной сети. Обучение направлено на распознавание состояний турбовентиляторного двигателя (нормального режима работы и неисправностей). В качестве входных данных использовался dataset с данными датчиков, записанными при различных состояниях системы. На основе полученной модели для диагностики был реализован программный модуль.

**Данные RUL.** В этой статье используется набор данных моделирования деградации турбовентиляторного двигателя [6]. Набор данных содержит данные временных рядов от запуска до

отказа для четырех различных наборов, смоделированных при различных комбинациях условий эксплуатации и режимов неисправностей.

В статье используется только набор данных FD001, который далее разделен на обучающие и тестовые подмножества. Подмножество обучения содержит смоделированные временные ряды данных для 100 двигателей. Каждый двигатель имеет несколько датчиков, значения которых регистрируются в заданном экземпляре в непрерывном процессе. Последовательность записанных данных различается по длине и соответствует экземпляру полного цикла работы до отказа. Подмножество тестирования содержит 100 частичных последовательностей и соответствующие значения оставшегося срока службы в конце каждой последовательности. Данные из файла заносятся в таблицу. Содержимое таблицы – предикторы, т. е. величины, используемые для прогнозирования обучения (сигналы сенсоров в данном случае) и соответствующие им ответы (оставшееся время службы RUL). Каждая строка – это отдельная машина.

На рис. 1 показаны временные ряды для некоторых предикторов, сигналы сенсоров в вольтах. Предварительная обработка включает удаление малоизменяющихся и постоянных признаков, нормализацию обучающих предикторов, т. е. получение среднего значения 0 и дисперсию 1.

Данные представляют значение RUL в течение срока службы для каждого двигателя и основаны на индивидуальном сроке службы двигателя. Чтобы сеть сосредоточилась на той части данных, где вероятность отказа двигателей выше (конец срока службы двигателя), нужно отсечь ответы на пороге 180. На рис. 2 показано первое наблюдение и соответствующий ответ (RUL) сразу после обрезания от здоровой зоны до отказа.

Эта сеть поддерживает входные данные с различной длиной последовательностей. При передаче данных через сеть программное обеспечение заполняет, отсекает или разделяет последовательности так, чтобы все последовательности в каждом мини-пакете имели указанную длину.

Обучающие данные сортируются по длине последовательности. При этом минимизируется заполнение мини-пакетов. Для равномерного распределения обучающих данных и уменьшения заполнения мини-пакетов выбирается нужный размер мини-пакета.

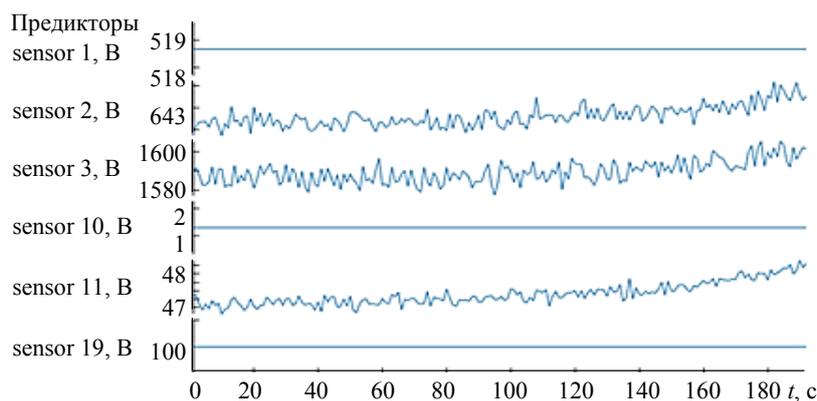


Рис. 1. Визуализация некоторых предикторов

Fig. 1. Visualization of some predictors

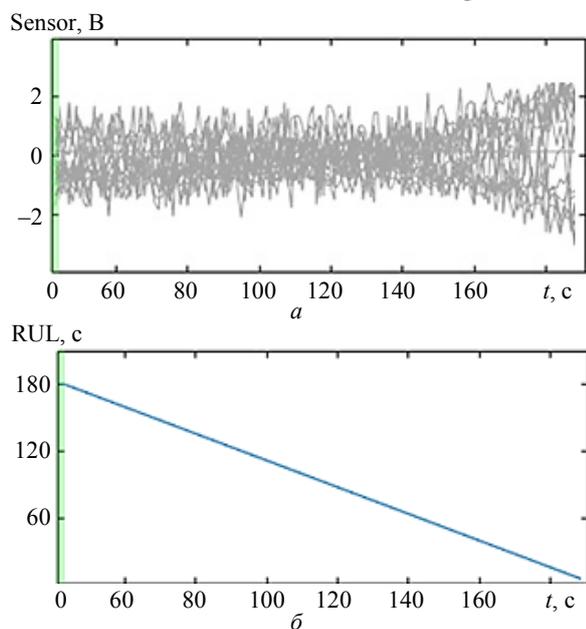


Рис. 2. График сигнала датчика (а); график RUL после обрезания на пороге (б)

Fig. 2. Graph of the sensor signal (a); graph of the RUL after clipping at the threshold (b)

**Архитектура сети.** Архитектура сети описана в [6]–[7]. Данные последовательности обрабатываются и сортируются. Здесь первое измерение представляет собой количество выбранных признаков, а второе – длину временной последовательности. Нужно объединить сверточные слои со слоем пакетной нормализации, за которым следует слой активации, а затем слои складываются вместе для извлечения признаков. Полностью связанные слои используются в конце для получения окончательного значения RUL в качестве выходных данных.

Выбранная архитектура сети применяет одномерную свертку только вдоль направления временной последовательности. Поэтому порядок признаков не влияет на обучение и одновременно учитываются только тенденции в одном признаке.

**Тренировка сети.** Deep Learning Toolbox используется в данном случае в качестве инструмента для обучения сверточной нейронной сети. Тренировка с помощью обучающего набора данных (training dataset) проводится в начале. На практике обучающий набор данных нужен для сравнения полученных результатов работы нейронной сети с реальными выходными данными. В результате такого сравнения с учетом используемого алгоритма машинного обучения параметры модели подстраиваются требуемым образом.

В Deep Learning Toolbox необходимо установить параметры тренировки. Набор данных представляет собой 40 эпох с мини-пакетами размером 16 с помощью оптимизатора Adam. Скорость обучения установлена на относительном безразмерном коэффициенте 0.01. Чтобы предотвратить чрезмерное изменение градиентов, пороговое значение градиента устанавливается на 1. При тренировке требуется сохранить последовательности отсортированными по длине. Включаем график хода обучения, чтобы просмотреть график среднеквадратичной ошибки RMSE (Root Mean Square Error) оценки RUL (рис. 3). Нужно также установить формат входных данных, поскольку данные обучения содержат признаки в первом измерении, последовательность временных рядов

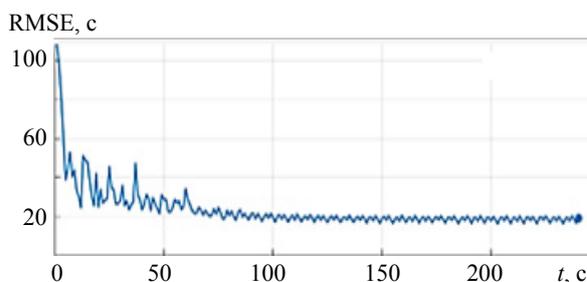


Рис. 3. Среднеквадратичная ошибка (RMSE)  
Fig. 3. Root Mean Square Error (RMSE)

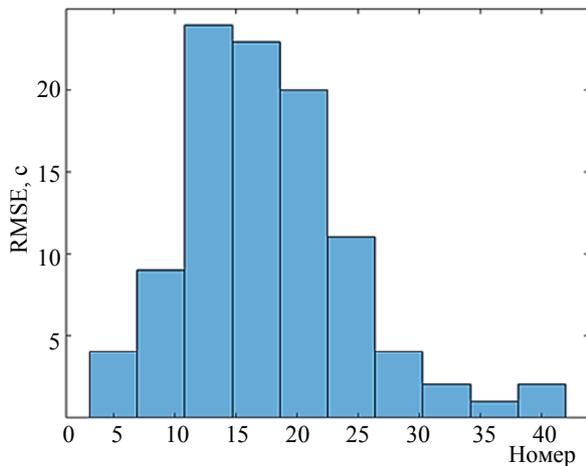


Рис. 4. Распределение значений RMSE по всем тестовым системам с номерами  
Fig. 4. Distribution of RMSE values across all test systems with numbers

во втором измерении и пакеты данных в третьем измерении. Далее запускаем процесс обучения и указываем функцию потерь как среднеквадратичную ошибку. Это занимает около 1–2 мин.

**Тестовая сеть.** Далее обученная модель подвергается валидации на основе второго набора данных, называемого проверочным набором данных (validation dataset), которая, в свою очередь, обучена с помощью обучающего набора данных.

На практике эта простая процедура осложняется возможным колебанием ошибки проверочного набора данных и появлением нескольких локальных минимумов. Здесь необходимо использовать разработанные правила для определения ситуаций, в которых началось переобучение. Наконец, тестовый набор данных (test dataset) проводит финишную оценку качества нейронной сети.

Тестовые данные – это 100 последовательностей. Каждая последовательность в конце содержит значения RUL.

В итоге необходимо создать таблицу для хранения прогнозируемого ответа ( $Y_{Pred}$ ) вместе с истинным ответом ( $Y$ ) и сделать прогнозы на основе тестовых данных. Чтобы не добавлять заполнение к тестовым данным, нужно указать размер мини-пакета как 1, чтобы получить значение RUL для каждого наблюдения в тестовых данных.

**Показатели производительности.** Следующей задачей служит оценка показателей производительности. Она осуществляется на основе сравнения с реальными данными, оценивается точность прогнозирования.

В данном случае следует вычислить среднеквадратичную ошибку (RMSE) по всем времен-

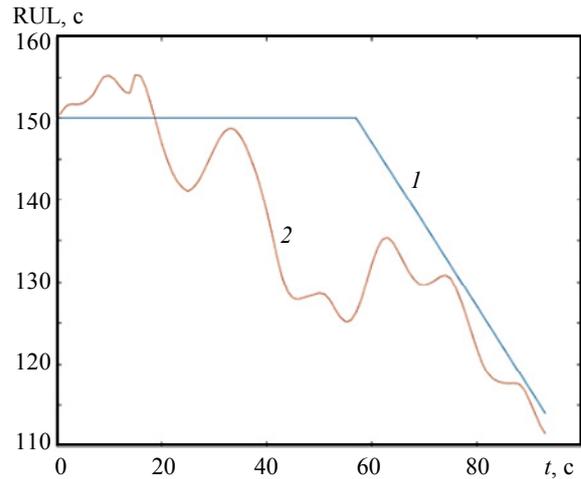


Рис. 5. Графики прогнозируемого (2) и истинного (1) RUL случайного тестового механизма

Fig. 5. The graph of the predicted RU versus the true RUL of the random test mechanism

ным циклам тестовых последовательностей, чтобы проанализировать, насколько хорошо сеть работает на тестовых данных. Для проведения анализа создаем гистограмму для визуализации распределения значений RMSE по всем тестовым системам (рис. 4).

Кроме того, чтобы увидеть, как сетевой предиктор работает на заданной последовательности данных в тестовых механизмах, строим график прогнозируемого RUL (кривая 2) в сравнении с истинным RUL (кривая 1) случайного тестового механизма (рис. 5).

**Закключение.** Результат, представленный на рис. 5, показывает, что архитектура глубокого обучения CNN для оценки RUL данных турбодвигателя представляет собой жизнеспособный подход для прогнозирования RUL. Значения RMSE на всех временных метках указывают на то, что сеть может хорошо работать к концу данных заданной последовательности испытаний. Поэтому наличие краткой истории данных датчика важно при попытке прогнозирования RUL. В результате вычислительных экспериментов показано, что предлагаемая модель, основанная на сверточной нейронной сети (CNN), способна дать более высокую точность.

Научная новизна предлагаемого подхода определяется следующими моментами:

1. Предложением новой нейросетевой архитектуры системы диагностики для прогнозирования возникновения неисправностей.
2. Предложением новой нейросетевой методики оценки прогнозирования RUL.
3. Предложенный алгоритм диагностики демонстрирует высокую точность и эффективность.

### Список литературы

1. Иванько А. Ф., Иванько М. А., Сизова Ю. А. Нейронные сети: общие технологические характеристики // Науч. обозрение. Техн. науки. 2019. № 2. С. 17–23. URL: <https://science-engineering.ru/ru/article/view?id=1236> (дата обращения: 09.06.2025).
2. Галушкин А. И. Нейронные сети: основы теории. М.: Горячая линия-Телеком, 2010. 496 с.
3. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. 2-е изд., испр. М.: ДМК Пресс, 2018. 652 с.
4. Babu G. S., Zhao P., Li X.-L. Deep convolutional neural network based regression approach for estimation of remaining useful life // Intern. Conf. on Database Syst. for Advanced Appl. (DASFAA). Dallas, TX, USA: Springer, 2016. P. 214–228. doi: 10.1007/978-3-319-32025-0\_14.
5. Li X., Ding Q., Sun J.-Q. Remaining useful life estimation in prognostics using deep convolution neural networks // Reliability Engin. & Syst. Safety. 2018. Vol. 172. P. 1–11. doi: 10.1016/j.res.2017.11.021.
6. Jardine A. K. S., Lin D., Banjevic D. A review on machinery diagnostics and prognostics implementing condition-based maintenance // Mechanical Syst. and Signal Proc. 2006. Vol. 20, no. 7. P. 1483–1510. doi: 10.1016/j.ymsp.2005.09.012.
7. Feature selection using support vector machines / J. Brank, M. Grobelnik, N. Milic-Frayling, D. Mladenić // Proc. of the 3<sup>rd</sup> Intern. Conf. on Data Mining Methods and Databases for Engin., Finance, and Other Fields. Bologna, Italy: WIT Press, 2002. Vol. 28. P. 1–13.

### Информация об авторах

**Кораблев Юрий Анатольевич** – канд. техн. наук, доцент, зам. зав. кафедрой автоматизации и процессов управления СПбГЭТУ «ЛЭТИ».

E-mail: [juri.korablev@gmail.com](mailto:juri.korablev@gmail.com)

<https://orcid.org/0000-0002-2432-7169>

**Лосева Дарья Михайловна** – аспирант кафедры автоматизации и процессов управления СПбГЭТУ «ЛЭТИ».

E-mail: [d.m.loseva@gmail.com](mailto:d.m.loseva@gmail.com)

**Шестопалов Михаил Юрьевич** – д-р техн. наук, доцент, зав. кафедрой автоматизации и процессов управления СПбГЭТУ «ЛЭТИ».

E-mail: [shestopalov\\_08@mail.ru](mailto:shestopalov_08@mail.ru)

### References

1. Ivan'ko A. F., Ivan'ko M. A., Sizova Ju. A. Nejrionnye seti: obshhie tehnologicheskie harakteristiki // Nauch. obozrenie. Tehn. nauki. 2019. № 2. S. 17–23. URL: <https://science-engineering.ru/ru/article/view?id=1236> (data obrashhenija: 09.06.2025). (In Russ.).
2. Galushkin A. I. Nejrionnye seti: osnovy teorii. M.: Gorjachaja linija-Telekom, 2010. 496 s. (In Russ.).
3. Gudfellou Ja., Bendzhio I., Kurvill' A. Glubokoe obuchenie / per. s angl. A. A. Slinkina. 2-e izd., ispr. M.: DMK Press, 2018. 652 s. (In Russ.).
4. Babu G. S., Zhao P., Li X.-L. Deep convolutional neural network based regression approach for estimation of remaining useful life // Intern. Conf. on Database Syst. for Advanced Appl. (DASFAA). Dallas, TX, USA: Springer, 2016. P. 214–228. doi: 10.1007/978-3-319-32025-0\_14.
5. Li X., Ding Q., Sun J.-Q. Remaining useful life estimation in prognostics using deep convolution neural networks // Reliability Engin. & Syst. Safety. 2018. Vol. 172. P. 1–11. doi: 10.1016/j.res.2017.11.021.
6. Jardine A. K. S., Lin D., Banjevic D. A review on machinery diagnostics and prognostics implementing condition-based maintenance // Mechanical Syst. and Signal Proc. 2006. Vol. 20, no. 7. P. 1483–1510. doi: 10.1016/j.ymsp.2005.09.012.
7. Feature selection using support vector machines / J. Brank, M. Grobelnik, N. Milic-Frayling, D. Mladenić // Proc. of the 3<sup>rd</sup> Intern. Conf. on Data Mining Methods and Databases for Engin., Finance, and Other Fields. Bologna, Italy: WIT Press, 2002. Vol. 28. P. 1–13.

### Information about the authors

**Yury A. Korablev** – Cand. Sci. (Eng.), Associate Professor, Deputy Head of the Department of Automation and Control Processes, Saint Petersburg Electrotechnical University.

E-mail: [juri.korablev@gmail.com](mailto:juri.korablev@gmail.com)

<https://orcid.org/0000-0002-2432-7169>

**Daria M. Loseva** – postgraduate student of the Department of Automation and Control Processes, Saint Petersburg Electrotechnical University.

E-mail: d.m.loseva@gmail.com

**Mikhail Yu. Shestopalov** – Dr Sci. (Eng.), Associate Professor, Head of the Department of Automation and Control Processes, Saint Petersburg Electrotechnical University.

E-mail: shestopalov\_08@mail.ru

Статья поступила в редакцию 13.05.2025; принята к публикации после рецензирования 07.06.2025; опубликована онлайн 29.09.2025.

Submitted 13.05.2025; accepted 07.06.2025; published online 29.09.2025.

---