

УДК 004.93'14

<https://doi.org/10.32362/2500-316X-2021-9-2-78-87>

НАУЧНАЯ СТАТЬЯ

Идентификация темпоральных аномалий спектрограмм сигналов виброизмерений ротора турбогенератора с применением рекуррентного нейросетевого автоэнкодера

В.П. Кулагин[®],
Д.А. Акимов,
С.А. Павельев,
Е.О. Гурьянова

МИРЭА – Российский технологический университет, Москва, 119454 Россия

[®] Автор для переписки, e-mail: kulagin@mirea.ru

Резюме. Предлагается метод распознавания предаварийных состояний роторных установок на основе применения окна Хэмминга и перспективных методик Deep Learning в ретроспективном анализе результатов учета факторов эксплуатации турбогенератора, диагностики и контроля при критических воздействиях. Разработана программа экспериментальных исследований на модели турбоустановки с имитацией неисправностей и получения вибросигналов. Эксперимент на основе гомостатичного метода проверки сигнала окнами Хэмминга в частотной, временной и модуляционной областях и единых исходных данных позволяет определить наиболее перспективные для идентификации характеристики сигнала. Разработана методика осуществления мониторинга состояния турбогенераторов в автоматическом режиме для своевременного оповещения персонала тепловой электростанции (ТЭС) о появлении признаков предаварийных ситуаций, а также о характере неисправностей методом прогнозирования состояния предаварийной ситуации с помощью сверточных нейронных сетей с реализацией в виде рекуррентного автоэнкодера. Применяется кластеризация, и выявляются кластеры, соответствующие спектрограммам предаварийных ситуаций. Результативность применения гомостатичного метода в сочетании с корреляционным анализом основана на модели принятия решений, более подробно изложенной в других работах. Рассмотрено использование глубоких нейронных сетей при обнаружении классов признаковового пространства предаварийных ситуаций на промышленных турбогенераторах. Дана методика подготовки обучающей выборки и обучения глубокой нейронной сети при классификации аномалий спектрограмм. Диагностика дефектов выполняется на основе заранее сформированных экспериментальных баз данных и обобщенных баз знаний, ставящих в соответствие повышенный уровень виброактивности с вызвавшими ее причинами. Различные дефекты активных частей турбогенератора, возникающие в процессе эксплуатации, требуют аварийного останова генератора, что является крайне нежелательным событием для станции.

Ключевые слова: нейронные сети, предиктивная аналитика, окна Хэмминга, прогнозирование неисправностей, вибродиагностика, анализ спектрограмм, вибрационный стенд, турбогенератор, рекуррентный автоэнкодер

• Поступила: 11.12.2020 • Доработана: 25.12.2020 • Принята к опубликованию: 09.01.2021

Для цитирования: Кулагин В.П., Акимов Д.А., Павельев С.А., Гурьянова Е.О. Идентификация темпоральных аномалий спектрограмм сигналов виброизмерений ротора турбогенератора с применением рекуррентного нейросетевого автоэнкодера. *Российский технологический журнал*. 2021;9(2):78–87. <https://doi.org/10.32362/2500-316X-2021-9-2-78-87>

Прозрачность финансовой деятельности: Никто из авторов не имеет финансовой заинтересованности в представленных материалах или методах.

Авторы заявляют об отсутствии конфликта интересов.

RESEARCH ARTICLE

Identification of temporal anomalies of spectrograms of vibration measurements of a turbine generator rotor using a recurrent neural network autoencoder

Vladimir P. Kulagin[@],
Dmitry A. Akimov,
Sergey A. Pavelyev,
Ekaterina O. Guryanova

MIREA – Russian Technological University, Moscow, 119454 Russia

[@] Corresponding author, e-mail: kulagin@mirea.ru

Abstract: A method is proposed for recognizing pre-emergency conditions of rotary installations based on the use of the Hamming window and advanced Deep Learning techniques in retrospective analysis of the results of accounting for the factors of operation of a turbine generator, diagnostics and control under critical impacts. A program of experimental studies on the model of a turbine plant with simulation of faults and receiving vibration signals has been developed. An experiment based on the homostatic method of checking the signal with Hamming windows, in the frequency, time and modulation domains and common initial data, allows one to determine the most promising signal characteristics for identification. A method has been developed for monitoring the state of turbine generators in an automatic mode for timely notification of the CHPP personnel about the appearance of signs of pre-emergency situations, as well as about the nature of faults by the method of predicting the state of a pre-emergency situation using convolutional neural networks implemented in the form of a recurrent autoencoder. Clustering is applied and clusters are identified that correspond to the spectrograms of pre-emergency situations. The effectiveness of the use of the homostatic method in combination with correlation analysis is based on the decision-making model described in more detail in other works.

Keywords: neural networks, predictive analytics, Hamming windows, fault prediction, vibration diagnostics, spectrogram analysis, vibration stand, turbine generator, recurrent autoencoder

• Submitted: 11.12.2020 • Revised: 25.12.2020 • Accepted: 09.01.2021

For citation: Kulagin V.P., Akimov D.A., Pavelyev S.A., Guryanova E.O. Identification of temporal anomalies of spectrograms of vibration measurements of a turbine generator rotor using a recurrent neural network autoencoder. *Rossiiskii tekhnologicheskii zhurnal = Russian Technological Journal*. 2021;9(2):78–87 (in Russ.). <https://doi.org/10.32362/2500-316X-2021-9-2-78-87>

Financial Disclosure: No author has a financial or property interest in any material or method mentioned.

The authors declare no conflicts of interest.

ВВЕДЕНИЕ

В настоящее время в условиях нарастающей мощности вырабатываемой и потребляемой энергии актуальной задачей является автоматический контроль агрегатов электростанций в реальном времени. Однако имеет место нехватка аналитиков-экспертов, способных анализировать спектрограммы вибродиагностики турбогенераторов, регистрируемых вибродатчиками в режиме постоянного наблюдения, для распределенной энергетики.

Таким образом, необходима разработка автоматизированных интеллектуальных систем для мониторинга вибросостояний турбогенераторов ТЭС в режиме online с функцией прогнозирования аварийных ситуаций.

Реализация указанного метода позволит классифицировать вибросостояния турбогенераторов на основе использования нейросетевой обработки измерительных данных виброизмерений, представленных в спектральном виде, и знаний экспертов, имеющих опыт интерпретации спектрограмм, характеризующих вибросостояния турбогенераторов ТЭС, в автоматическом режиме.

Методика экспериментальных испытаний для оценки вибраций и прогнозирования состояния объекта описана в работах ряда исследователей. В работе [1] анализируется частота механических колебаний двигателя с короткозамкнутым ротором и идентичный двигатель, работающий под эксцентриситетом динамического ротора. Радиальные колебания моделируются на основе экспериментальных данных в режимах работы без нагрузки и номинальной нагрузки. Основное внимание уделяется частоте вибрации и разбросу колебаний частоты. Указывается необходимость дальнейшего изучения методов распознавания вибраций. Предложенный в [2] метод анализа работы подшипников отличается более детальным описанием диагностики спектров дефектных состояний. Работа [3] описывает новый подход к выявлению дефектов подшипников, а именно, спектральные изображения вибрационных сигналов. Изображения спектра просто получаются быстрым преобразованием Фурье. Такие изображения обрабатываются с использованием двумерного анализа основных компонентов (2DPCA) для уменьшения размеров признакового пространства, а затем к полученным результатам применяется метод минимального расстояния для классификации неисправностей подшипников [4]. Эффективность предлагаемого метода подтверждается экспериментальными данными.

Целью настоящей работы является разработка метода распознавания спектрограмм предаварийной ситуации на основе ретроспективной выборки

и проведение экспериментальных исследований на стенде. Для этого в составе технических средств был собран и настроен испытательный стенд AP 7000, осуществляющий имитацию сигналов, измеряемых вибродатчиками турбогенератора, и предназначенный для исследований экспериментального программного комплекса, обеспечивающего мониторинг состояния турбогенераторов ТЭС в автоматическом режиме с использованием технологий нейросетевой классификации спектрограмм виброизмерений.

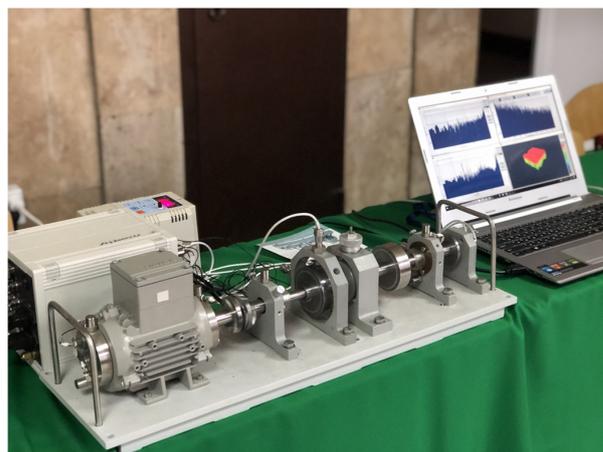


Рис. 1. Общая схема имитационного стенда AP 7000

Электромеханическая часть экспериментального стенда представляет из себя имитатор промышленного оборудования с вращающимися узлами машин и механизмов. В его состав входит электродвигатель Siemens 1LA7053-2AA10 мощностью 115 Вт и скоростью вращения ротора до 3000 об/мин.

Оперативная информация о значениях основных вибрационных периметров поступает потоком от объекта в блок допускового контроля с интервалом времени около 0.2 с. Выбор интервала обусловлен минимальным временем съема информации. Текущая информация представляется оператору по вибродиагностике в виде цветных графических спектрограмм комплекса и таблиц, в которых отображаются расчетные показатели.

Эта информация подается на вход блока диагностирования технического состояния турбогенератора, активизируемого по результатам допускового контроля. В этом же блоке переданная информация с объекта дополняется информацией о значениях технологических параметров для формирования двоичного вектора состояния.

Для обработки сигналов в блок диагностирования вызывается априорная экспертная информация. Она, как и другие необходимые данные, предварительно записывается в память. Обмен информацией между блоками технологического диагностирования и оператором осуществляется в диалоговом режиме.

МЕТОДИКА ПРОГНОЗИРОВАНИЯ НЕИСПРАВНОСТЕЙ

В процессе работы турбогенератора существует возможность прогнозировать отказы с помощью распознавания спектрограмм и интерполяции во времени. Существуют классы неисправностей, которые можно выделить в отдельные кластеры.

Для проводимых исследований был разработан экспериментальный программный комплекс, обеспечивающий мониторинг состояния турбогенераторов ТЭС в автоматическом режиме с использованием технологий нейросетевой классификации спектрограмм виброизмерений [5]. Экспериментальный программный комплекс функционирует под управлением операционной системы MS Windows XP/Vista/7 с установленным пакетом *Net Framework* версии не ниже 4.

Рассмотрим соединение ротора с подшипником качения. Если внутреннее кольцо подшипника качения посажено на вал с недостаточным натягом, то между этим кольцом и валом может возникнуть нежелательная ротация. Такая ротация, называемая проскальзыванием, приводит к круговому смещению кольца относительно вала. При появлении проскальзывания контактирующие поверхности истираются, что вызывает износ и значительное повреждение вала [6].

Ослабление посадки вращающейся детали на валу влияет на дисбаланс вращения ротора, который проявляется как периодические колебания амплитуды отклонения вала ротора от центральной оси, происходящие с частотой вращения вала.

На спектрограмме (рис. 2) запечатлен момент обнаружения вибродатчиками, расположенными на

вала и на подшипнике, гармоник, свидетельствующих о проскальзывании вала – неисправность «недостаточный натяг подшипника».

В роторных установках вибрационные колебания и их спектр удобно описывать моделью полигармонического возбуждения, представленной формулой (1). Подобная модель позволяет выделить определенные частоты $k\omega_r$, кратные основной частоте вращения ротора:

$$x(t) = \sum_k A_k(t) \cos[k\omega_r t - \varphi_k(t)] + \psi(t), \quad (1)$$

где $k\omega_r$ – средняя частота узкополосного процесса вибрационных колебаний; $A_k(t)$ – случайная, медленно меняющаяся огибающая узкополосного процесса вибрационных колебаний; $\varphi_k(t)$ – случайная, медленно меняющаяся фаза; $\psi(t)$ – шумовое возбуждение.

Погрешности изготовления и монтажа деталей, температурные изменения геометрических параметров деталей и зазоров в сочленениях, изменение вязкости смазки, искажение формы и качества поверхностей взаимодействующих деталей с нагрузкой, наконец, нестабильность оборотов вала двигателя, вызванная, например, нестабильностью частоты сетевого напряжения, и множество других случайных факторов приводят к флуктуациям амплитуд и размытию дискретных линий спектра полигармонических колебаний [7].

При возникновении дефекта спектрограмма меняется, на ней появляются дополнительные всплески определенной частоты. Такие всплески можно видеть на двумерной и трехмерной спектрограмме, показанной на рис. 3, в случае повреждения баббита вкладышей

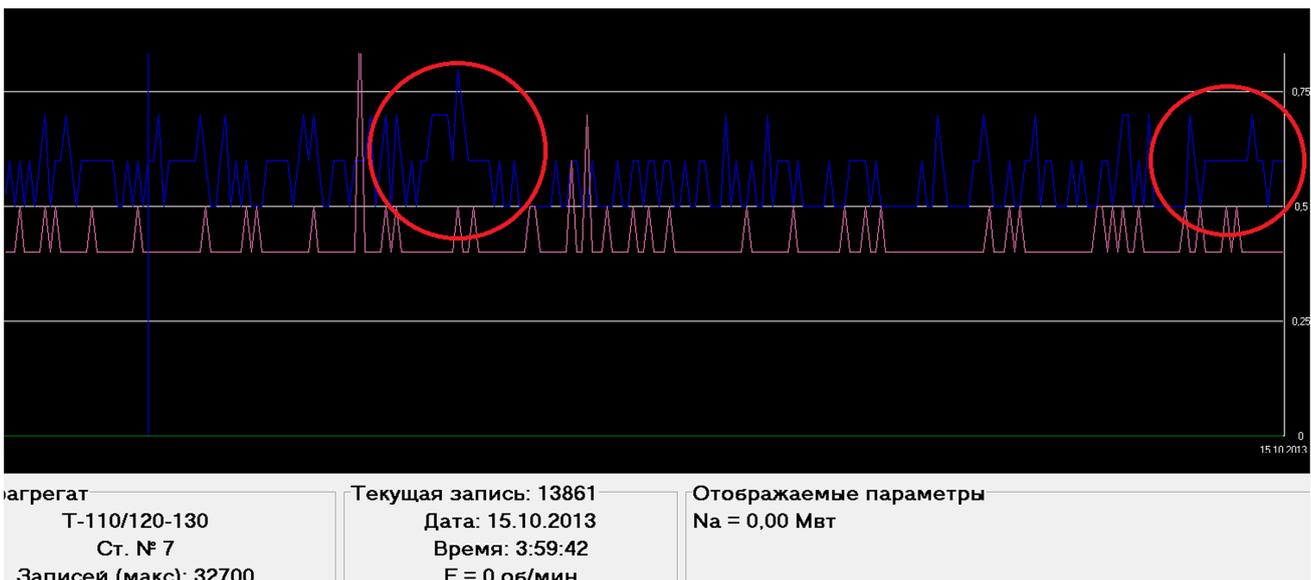


Рис. 2. Спектральный состав гармоник неисправности «недостаточный натяг подшипника»

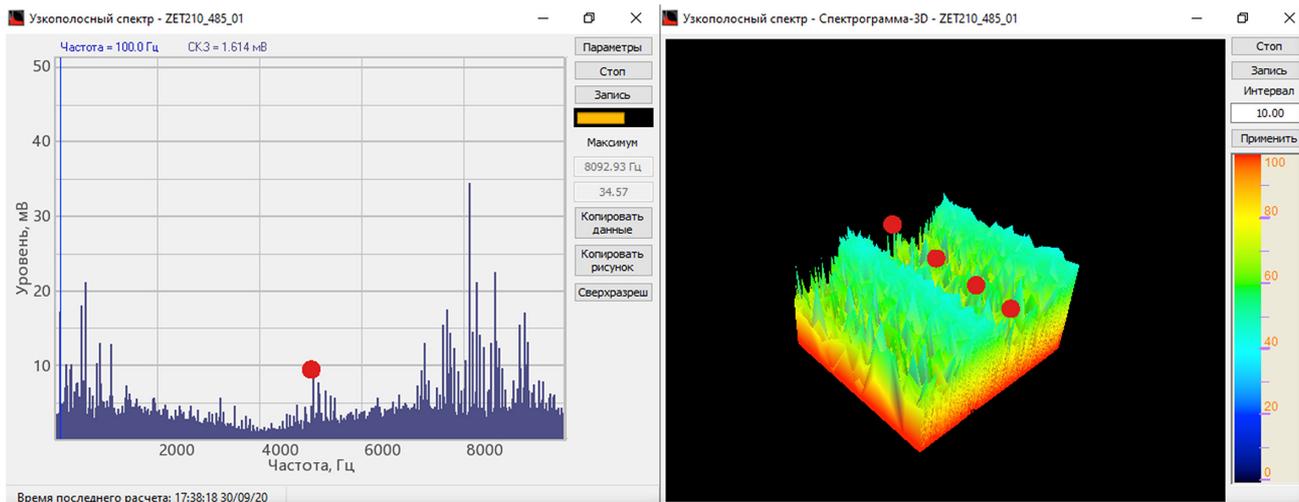


Рис. 3. Гармоники неисправности «Повреждение баббита вкладышей» на темпоральной записи спектрограммы

подшипников. На спектрограмме видно появление гармоники на 4630 Гц, а также видна ее периодичность на трехмерном графике, что свидетельствует о периоде появления самой гармоники. Применяя импульсную модель к описанию всплесков частоты, можно вычленивать новые импульсы периодического появления гармоник, отмеченных красными точками на трехмерной спектрограмме (рис. 3), соответствующие определенному дефекту. Обозначим такой импульс через функцию $f(t)$, тогда представим периодическую последовательность импульсов в виде:

$$\xi(t) = \sum_k (t - t_k), \quad (2)$$

где $t_k = kT + t_0$; k – целое число; T – период вращения вала; t_0 – время возникновения первого импульса.

Развитие дефекта вызывает рост амплитуд и числа кратковременных импульсов гармоники в вибросигнале, вызванных дефектом [8].

Выявить зарождающийся дефект, который меняет структуру спектра, можно методами оконного преобразования сигнала, который сводит к минимуму влияние помех и позволяет однозначно соотнести полученную характеристику сигнала с видом дефекта. Таким преобразованием, выделяющим аномальные компоненты, является преобразование с помощью окна Хэмминга в частотно-временной области нестационарного сигнала.

Рассмотрим прямоугольное окно

$$w_H(n) = \begin{cases} 0, & n < -\left(\frac{N-1}{2}\right) \\ \alpha + (1-\alpha)\cos\left(\frac{2\pi n}{N}\right), & -\left(\frac{N-1}{2}\right) \leq n \leq \frac{N-1}{2} \\ 0, & n > \frac{N-1}{2} \end{cases}, \quad (3)$$

где $w_H(n)$ – весовая функция окна Хэмминга при экспериментально установленной $\alpha = 0.54$ (случай для окна Хэмминга); N – ширина окна; n – целое число.

Частотную характеристику рассматриваемого окна можно получить как произведение прямоугольного окна (3) и окна Хэмминга (при $\alpha = 0.54$) для всех n :

$$w_H(n) = w_R(n) \left[\alpha + (1-\alpha)\cos\left(\frac{2\pi n}{N}\right) \right], \quad (4)$$

где $w_R(n)$ – весовая функция прямоугольного окна с высотой 1.

Само прямоугольное окно можно задать частотной характеристикой [9]:

$$W_R(e^{j\omega}) = \frac{\sin(\omega N / 2)}{\sin(\omega / 2)}. \quad (5)$$

Частотная характеристика обобщенного окна Хэмминга равна круговой свертке частотной характеристики прямоугольного окна с последовательностью импульсов и может быть записана в виде:

$$W_H(e^{j\omega}) = W_R(e^{j\omega}) \times \left[\alpha u_0(\omega) + \frac{1-\alpha}{2} u_0\left(\omega - \frac{2\pi}{N}\right) + \frac{1-\alpha}{2} u_0\left(\omega + \frac{2\pi}{N}\right) \right]. \quad (6)$$

Применяя наилучшее окно высокого разрешения, конкретное окно Хэмминга зададим выражением [9]:

$$w_H(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right), \text{ при } N = 2 \quad (7)$$

где N – коэффициент ширины окна.

Применяя окно Хэмминга к нестационарному сигналу в случае дефекта подшипника, можно увидеть появление аномалии, показанной на рис. 4 – результате обработки спектрограммы.

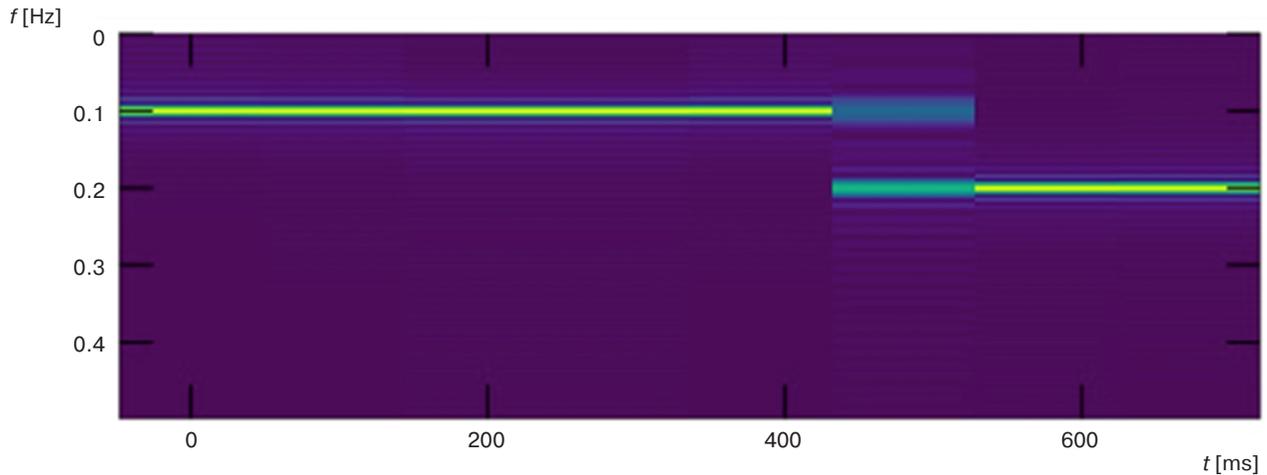


Рис. 4. Выявление аномалии разрыва спектра с помощью применения окна Хэмминга для спектрограммы, где f – частота, t – время. Интенсивность сигнала определяется градиентом цветовой палитры

Из рис. 4 видно разделение полосы спектра, обработанного с помощью окна Хэмминга. Сдвиг приведенной амплитуды спектра на рис. 4 и 5 отображает резкий скачок в частотной области, что свидетельствует об аномалии [10].

На рис. 6 отображена обработка исходного сигнала с выявленной аномалией.

Применение окна Хэмминга является только первым этапом к выявлению аномалий. В приведенных результатах показано его применение с $N = 2$, однако данный метод имеет свои ограничения [11]. Аномалии не всегда обозначают наличие дефекта или будущей неисправности, управляемая смена фазы или режима может также восприниматься методом как аномалия. Поэтому требуется дополнительная интеллектуальная обработка результатов применения окна Хэмминга, например, с помощью глубоких нейросетевых методов.

Для того, чтобы найти корреляцию между прогнозируемым состоянием турбогенератора и известным состоянием экспериментального стенда необходимо рассмотреть состояние турбины как вектор предикторов дефектов и выбрать наиболее критичные из них, обработанные с помощью окна Хэмминга [12].

Классом моделей, успешно решающих задачу корреляции, являются сверточные нейронные сети (Convolutional Neural Network, CNN). CNN относятся к парадигме машинного обучения «deep learning», которая очень хорошо себя зарекомендовала в задачах распознавания аномалий вибросигнала [13]. На основе применения глубоких нейронных сетей можно задать рекуррентные автоэнкодеры. Принцип их использования заключается в последовательном применении операций свертки с последующей рекурсией и выбором максимального значения

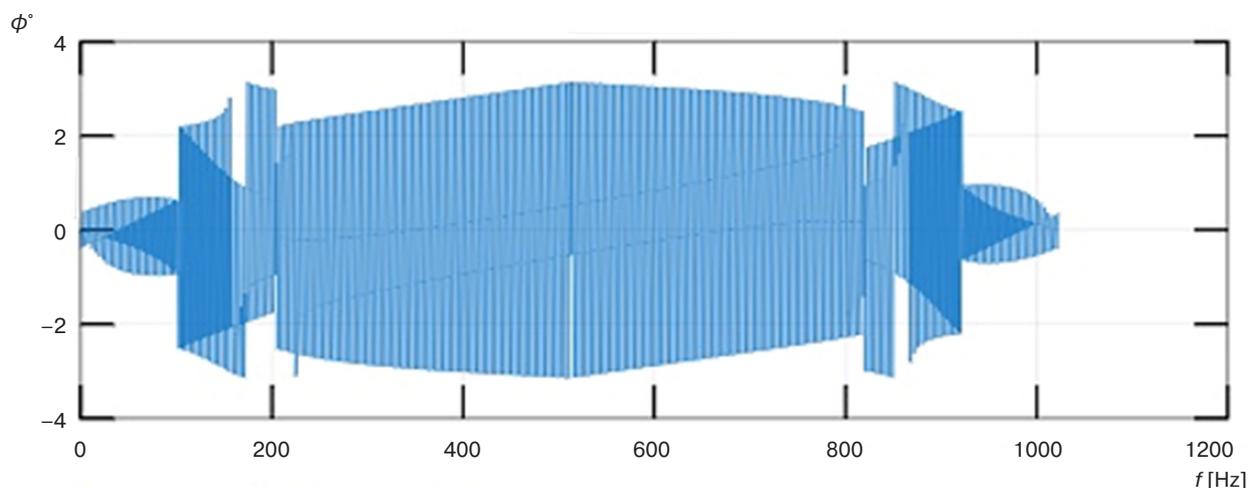


Рис. 5. Выявление аномалии с помощью применения окна Хэмминга для вибросигнала, где f – частота, ϕ – значение приведенной фазы в градусах

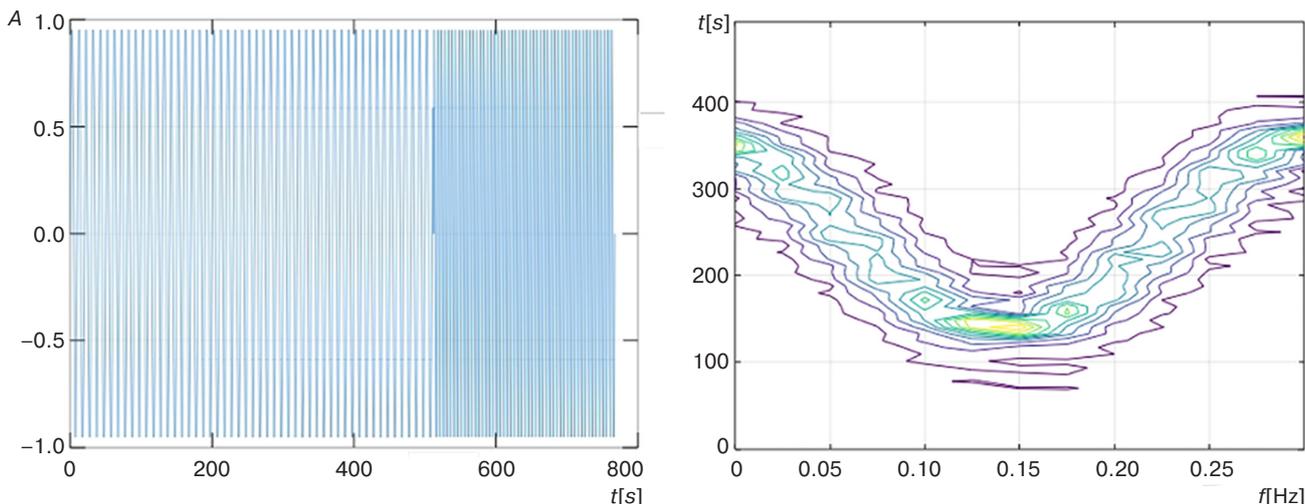


Рис. 6. Детализация сигнала с аномалией с применением окна Хэмминга, где A – амплитуда; t – время; f – частота

(max-polling). Рекуррентный автоэнкодер на основе UNET для анализа измерительных данных схематически изображен на рис. 7.

Чтобы получить данные об аномалии, сверточную нейронную сеть необходимо проверить на практике, оценив возможность решать задачу

корреляционного сопоставления аномалии с нормальным образом (без аномалий).

Рекуррентные слои 2xConv выделяют пространство признаков спектрограмм, позволяющее найти подходящую критическую причину дефекта, отображенную на спектрограмме [14].

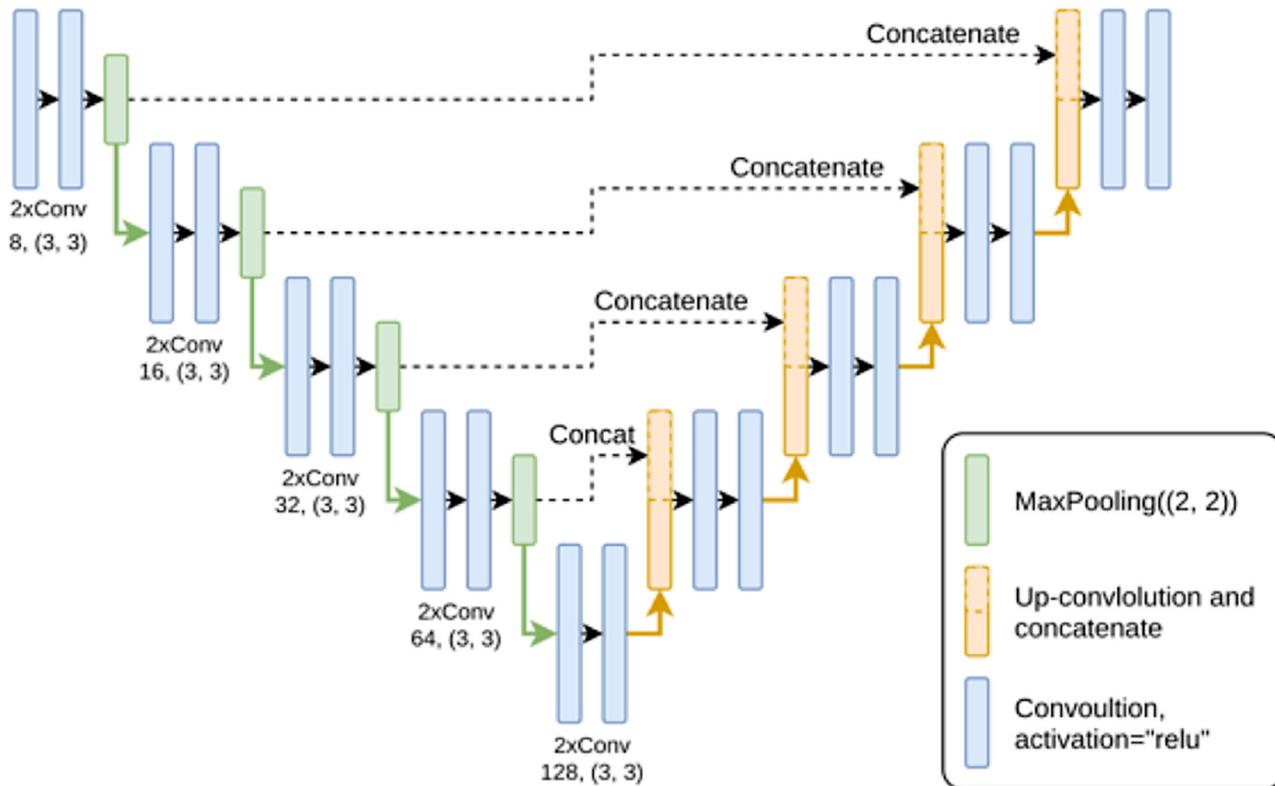


Рис. 7. Автоэнкодер на базе нейронной сети. Обозначения на рисунке: 2xConv (3×3) – свертка с ядром 3×3 ; Concatenate – операция слияния признаков, MaxPooling((2, 2)) – операция максимального объединения признаков; Up-convolution and concatenate – операция повышающей дискретизации карты свойств; Convolution activation = “relu” – активационная функция вида ReLU (Rectified linear unit)

На выходе автоэнкодера получаем вектор $L(l_1, \dots, l_n)$, где l_1, \dots, l_n – коэффициенты корреляции с кластером q , что и является результатом обучения нейронной сети.

В результате проведенного эксперимента были заданы обучающая и тестовая выборки в виде оцифрованных сигналов по 400 образцам спектрограмм. Далее все образцы прошли этапы предобработки спектрограмм. При этом полученные матрицы признаков подавались на вход нейронной сети.

Основой для проверки правильности предсказания критериальной переменной (корреляции) от предиктора выбрана ошибка обучения:

$$E_k = \frac{1}{2} \sum_{i=0}^{N-1} (d_i - o_i)^2, \quad (8)$$

где N – число выходов сети; d_i – желаемое значение i -го выхода сети для k -го эталона; o_i – реальное значение i -го выхода сети для k -го эталона. Величина E_k должна вычисляться для каждого элемента обучающей выборки.

В качестве критерия в исследовании использовалась величина средней ошибки при сравнении с каждым эталоном:

$$\bar{E}(n) = \frac{1}{S} \sum_{k=0}^{S-1} E_k, \quad (9)$$

где S – мощность обучающей выборки; $\bar{E}(n)$ – средняя ошибка сети для n -й эпохи обучения.

На выходе нейронной сети были получены коэффициенты корреляции кластеров [15, 16]. Чем больше коэффициент корреляции на выходе, тем вероятнее, что именно в это рассматриваемое состояние попадет ротор турбогенератора с течением времени. Однако набор возможных состояний изначально задан в базе знаний экспертным методом. При таких данных можно проверить, как коррелируют экспертные оценки с оценкой нейронной сети.

РЕЗУЛЬТАТЫ

В ходе эксперимента было рассмотрено 16 440 записей спектрограмм турбогенератора и экспериментальной установки. При формировании обучающих векторов найдено 23% валидных спектрограмм относительно соответствия неисправному состоянию, из них 58% показало коэффициент корреляции выше 0.7 при сопоставлении данных с турбогенератором.

Логирование позволяет визуализировать ход обучения, например, просматривать, как менялись значения функции потерь с 3.6 до 0.5 (рис. 8).

Визуализацию выходных векторов в скрытом пространстве можно представить как пространство коррелированных признаков, сгруппированных в классы.

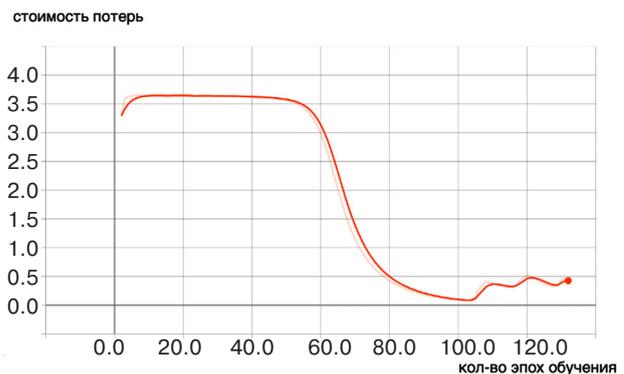


Рис. 8. График значений функции потерь

После обучения рекуррентного автоэнкодера программа сохраняет вектора скрытого пространства для валидационной выборки в файле `latent_vectors.csv`.

Вектора имеют размерность `latent_size`, по умолчанию равную 100. Чтобы визуализировать многомерное пространство используются следующие техники: анализ главных компонент (PCA) и t-SNE.

По результатам отбора классы с группировкой 0.64 показали коэффициент корреляции больше 0.7. В результате было выделено 4 класса неисправностей: дефект подшипника, расцентровка ротора, дефект опоры и протертость вкладышей.

ЗАКЛЮЧЕНИЕ

В работе предлагается подход к прогнозированию неисправностей турбогенератора на основе перспективных нейросетевых методик и хронологического анализа результатов работы при критических воздействиях.

В дальнейшем планируется перенести исследования с экспериментального стенда, имитирующего поведение турбогенератора ТЭЦ, на естественный промышленный образец с заведомо известной неисправностью. Предполагается, что более высокая амплитуда вибраций вала на промышленных генераторах может показать результаты корреляционного анализа, отличные от описанных в данной статье.

Описанные наработки могут быть использованы для создания технологий контроля безопасной работы промышленных установок с вибрирующими элементами.

Благодарности

Работа выполнена в рамках гранта «Университетский» ФГБОУ ВО «МИРЭА – Российский технологический университет» по теме «Выявление неявных неисправностей ответственных роторных агрегатов с помощью анализа темпоральных аномалий спектрограмм виброизмерений» (приказ № 1953 от 27.11.2019).

Вклад авторов. Все авторы в равной степени внесли свой вклад в исследовательскую работу.

Authors' contribution. All authors equally contributed to the research work.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Sobra J., Vaimann T., Belahcen A. Mechanical vibration analysis of induction machine under dynamic rotor eccentricity. In: *Proceedings of 17th International Scientific Conference on Electric Power Engineering (EPE)*. Prague, Czech Republic, 2016, p. 1–4. <https://doi.org/10.1109/EPE.2016.7521732>
2. Boudiaf A., Djebala A., Bendjma H., Balaska A., Dahane A. A summary of vibration analysis techniques for fault detection and diagnosis in bearing. In: *Proceedings of 8th International Conference on Modelling, Identification and Control (ICMIC)*. Algiers, Algeria, 2016, p. 37–42. <https://doi.org/10.1109/ICMIC.2016.7804187>
3. Wei Li, Mingquan Qiu, Zhencai Zhu, Bo Wu, Gongbo Zhou. Bearing fault diagnosis based on spectrum images of vibration signals. *Meas. Sci. Technol.* 2016;27(3): Article ID 035005. <https://doi.org/10.1088/0957-0233/27/3/035005>
4. Serdukova L., Kuske R., Yurchenko D. Post-grazing dynamics of a vibro-impacting energy generator. *J. Sound and Vibration.* 2020;492: Article ID 115811. <https://doi.org/10.1016/j.jsv.2020.115811>
5. Охтилев М.Ю., Соколов Б.В., Юсупов Р.М. *Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов*. М.: Наука; 2006. 410 с. ISBN 5-02-033789-7
- [Okhtilev M. Yu., Sokolov B. V., Yusupov R. M. *Intellektual'nye tekhnologii monitoringa i upravleniya strukturnoi dinamiko slozhnykh tekhnicheskikh ob'ektov (Intelligent monitoring and control technology of the structural dynamics of complex technical objects)*. Moscow: Nauka; 2006. 410 p. (in Russ.). ISBN 5-02-033789-7]
6. Будадин О.Н., Каледин В.О., Кульков А.А., Пичугин А.Н. Теоретические и экспериментальные исследования возможности теплового контроля пространственной конструкции из полимерного композиционного материала в процессе одноосного силового нагружения. *Контроль. Диагностика.* 2014;5(191):72–81. <https://doi.org/10.14489/td.2014.05.pp.072-080>
- [Budadin O.N., Kaledin V.O., Kulkov A.A., Pichugin A.N., Nagaitseva N.V. Theoretical and experimental study of thermal control applicability to a 3-D polymer composite structure under uniaxial power loading. *Kontrol'. Diagnostika = Testing. Diagnostics.* 2014;5(191):72–81 (in Russ.). <https://doi.org/10.14489/td.2014.05.pp.072-080>]
7. Акимов Д.А., Работкин В.Д., Терехин И.В., Редькин О.К. Представление знаний в распределительных информационных системах промышленных предприятий. *Промышленные АСУ и контроллеры.* 2013;1:33–38.
- [Akimov D.A., Rabotkin V.D., Terekhin I.V., Redkin O.K. Knowledge representation in distributed information systems industry. *Promyshlennyye ASU i kontrolyery = Industrial Automatic Control Systems and Controllers.* 2013;1:33–38 (in Russ.).]
8. Ostroukh A., Nikonov V., Ivanova I., Sumkin K., Akimov D. Development of the contactless integrated interface of complex production lines. *Journal of Artificial Intelligence (JAIR).* 2014;7(1):1–12. <https://dx.doi.org/10.3923/jai.2014.1.12>
9. Akimov D., Krug P., Ostroukh A., Ivchenko V., Morozova T., Sadykov I. The Simulation Model of the Autonomous Truck Caravan in the Extreme and Non-Stationary Environment. *Int. J. App. Eng. Res.* 2016;11(9):6435–6440.
10. Kulagin V.P., Ivanov A.I., Kuznetsov Y.M., Chulkova G.M. Multidimensional mutual ordering of patterns using a set of pre-trained artificial neural networks. *J. Phys.: Conf. Ser.* 2017;803(1): Article ID 012083. <https://doi.org/10.1088/1742-6596/803/1/012083>
11. Kulagin V., Akimov D., Pavelyev S., Potapov D. Automated Identification of Critical Malfunctions of Aircraft Engines Based on Modified Wavelet Transform and Deep Neural Network Clustering. *IOP Conf. Ser.: Materials Science and Engineering.* 2020;714(1): Article ID 012014. <https://doi.org/10.1088/1757-899X/714/1/012014>
12. Hashish E., Miller K., Finley W., Kreitzer S. Vibration Diagnostic Challenges: Case Studies in Electric Motor Applications. *IEEE Industry Applications Magazine.* 2017;23(4):22–34. <https://doi.org/10.1109/MIAS.2016.2600718>
13. Zhou S., Qian S., Chang W., Xiao Y., Cheng Y. A Novel Bearing Multi-Fault Diagnosis Approach Based on Weighted Permutation Entropy and an Improved SVM Ensemble Classifier. *Sensors.* 2018;18(6):1934. <https://doi.org/10.3390/s18061934>
14. Arun P., Madhukumar S., Careena P. A Method for the Investigation of Bearing Vibration Based on Spectrogram Image Comparison. *IOP Conf. Ser.: Materials Science and Engineering.* 2017;396(1): Article ID 012044. <https://doi.org/10.1088/1757-899X/396/1/012044>
15. Wen L., Gao L., Li X., Wang L., Zhu J. A Jointed Signal Analysis and Convolutional Neural Network Method for Fault Diagnosis. *Procedia CIRP.* 2018;72:1084–1087. <https://doi.org/10.1016/j.procir.2018.03.117>
16. Jayakumar K., Thangavel S. Industrial drive fault diagnosis through vibration analysis using wavelet transform. *J. Vib. Control.* 2017;23(12):2003–2013. <https://doi.org/10.1177/1077546315606602>

Об авторах

Кулагин Владимир Петрович, д.т.н., профессор, заведующий кафедрой КБ-5 «Аппаратное, программное и математическое обеспечение вычислительных систем» Института комплексной безопасности и специального приборостроения ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: kulagin@mirea.ru. ResearcherID B-1297-2014, Scopus Author ID 56912007700, <https://orcid.org/0000-0001-8826-6724>

Акимов Дмитрий Александрович, к.т.н., старший преподаватель кафедры «Автоматические системы» Института кибернетики ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: akimov_d@mirea.ru. ResearcherID U-5717-2018, Scopus Author ID 55531854400, <https://orcid.org/0000-0001-6889-618X>

Павельев Сергей Александрович, к.т.н., старший преподаватель кафедры «Автоматические системы» Института кибернетики ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: pavelv@mirea.ru. ResearcherID E-1577-2014, Scopus Author ID 56664390400, <https://orcid.org/0000-0003-1320-3061>

Гурьянова Екатерина Олеговна, старший преподаватель кафедры «Автоматические системы» Института кибернетики ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: guryanova@mirea.ru. Scopus Author ID 57216148759, <https://orcid.org/0000-0002-8809-8801>

About the authors

Vladimir P. Kulagin, Dr. Sci. (Eng.), Professor, Head of the Department of Hardware, Software and Mathematical Support of Computer Systems, Institute of Integrated Safety and Special Instrument Engineering, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: kulagin@mirea.ru. ResearcherID B-1297-2014, Scopus Author ID 56912007700, <https://orcid.org/0000-0001-8826-6724>

Dmitry A. Akimov, Cand. Sci. (Eng.), Senior Teacher, Automatic Systems Department, Institute of Cybernetics, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: akimov_d@mirea.ru. ResearcherID U-5717-2018, Scopus Author ID 55531854400, <https://orcid.org/0000-0001-6889-618X>

Sergey A. Pavelyev, Cand. Sci. (Eng.), Senior Teacher, Automatic Systems Department, Institute of Cybernetics, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: pavelv@mirea.ru. ResearcherID E-1577-2014, Scopus Author ID 56664390400, <https://orcid.org/0000-0003-1320-3061>

Ekaterina O. Guryanova, Senior Teacher, Automatic Systems Department, Institute of Cybernetics, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: guryanova@mirea.ru. Scopus Author ID 57216148759, <https://orcid.org/0000-0002-8809-8801>