

УДК 004.896

## АУГМЕНТАЦИЯ АУДИОДАНЫХ С КИБЕРФИЗИЧЕСКОГО УРОВНЯ ЦИФРОВЫХ ДВОЙНИКОВ ТЕХНОЛОГИЧЕСКИХ СИСТЕМ

**О. Д. Казаков**, к.э.н., доцент, проректор по цифровизации, заведующий кафедрой ИТ БГИТУ, Брянск, Россия;

orcid.org/0000-0001-9665-8138, e-mail: it.kazakov@yandex.ru

**Н. Ю. Азаренко**, к.э.н., доцент, магистрант БГИТУ, Брянск, Россия;

orcid.org/0000-0001-6644-418X, e-mail: salovanat@mail.ru

*Рассматривается задача аугментации аудиоданных с киберфизического уровня цифровых двойников технологических систем. Целью работы является оценка метрик качества моделей классификации работоспособности оборудования, обученных на одних и тех же нейросетевых архитектурах с одними и теми же настроенными гиперпараметрами, но на разных датасетах: оригинальном и расширенном на основе предложенных подходов: 1) алгоритм случайного блокирования диапазона последовательных частот, то есть блокировки некоторых участков спектрограммы; 2) добавление гауссова шума к спектрограмме. Аугментация данных, полученных при работе насосной станции AL-KO HW 3600 Easy 113798 на стадии проектирования киберфизического уровня ее цифровой копии, позволила увеличить набор данных до 392 объектов. Значения F-меры тестовой выборки Transfer learning на расширенном наборе данных после аугментации на основе предложенных алгоритмов во всех случаях выше, чем на оригинальном наборе данных. Данное исследование вносит определенный вклад в развитие использования нейронных сетей глубокого обучения к диагностике неисправностей оборудования. Предложенные методы позволяют достичь высокой точности диагностики с небольшим исходным набором данных, а также решают проблему повышения безопасности и надежности эксплуатации технологической системы в реальных условиях.*

**Ключевые слова:** цифровой двойник, технологическая система, аугментация аудиоданных, киберфизический уровень, transfer learning.

**DOI:** 10.21667/1995-4565-2022-80-127-133

### Введение

Использование цифрового двойника (ЦД) в технологических системах и процессах как тренда цифровизации обусловлено тем, что предприятие стремится оптимизировать процесс технического обслуживания и ремонтов, избегать дорогостоящих простоев. В этом случае цифровой двойник призван решать диагностическую роль, то есть диагностировать сбои и обнаруживать нештатное поведение технологического оборудования. Кроме того, преимуществами использования цифрового двойника для промышленного производства является, по мнению экспертов, дистанционный мониторинг и управление физическим объектом в режиме реального времени; повышение эффективности работы производства с большей автономией обслуживающего персонала; предикативное обслуживание и планирование ремонтов технологического оборудования с использованием сверточных нейронных сетей.

В структуре цифровых двойников технологических систем мы выделили следующие уровни: киберфизический уровень; уровень извлечения и препроцессинга данных; уровень моделей и алгоритмов; уровень визуализации и интерфейсов.

С киберфизического уровня цифрового двойника происходит извлечение нетипизированных данных, которые выгружаются с системы датчиков.

Для построения ЦД в технологических системах могут быть востребованы датчики для виброакустического исследования технологических систем. Для реализации моделей машинного обучения, позволяющих диагностировать поломки оборудования необходимо собрать соответствующие размеченные данные. Развитие использования нейронных сетей глу-

бокого обучения к диагностике неисправностей оборудования сдерживается высокими требованиями к объему обучающих данных.

Аугментация данных частично позволяет преодолеть проблему небольшого числа размеченных данных. Особенно это актуально для аудио-меток, ассоциированных с работой неисправного оборудования. Ученые Li X и другие предлагают методы увеличения данных для искусственного создания дополнительных достоверных выборок для обучения модели для диагностики неисправностей вращающихся механизмов, а именно дополнительный гауссовский шум, маскирующий шум, преобразование сигнала, сдвиг амплитуды и растяжение по времени [3, с.436].

### Теоретическая часть

Традиционные подходы к аугментации данных заключаются в синтезировании размеченных объектов на основе изменений в существующем наборе. Применительно к изображению это можно сделать путем его поворота, обрезки или масштабирования. Также можно поменять каналы цветов, добавить шум или изменить освещение. В этом случае семантика изображения существенно не меняется. Поэтому целевая метка, ассоциированная с оригиналом, тоже не меняется. Добавляя таким методом размеченные объекты, можно существенно расширить их число в датасете.

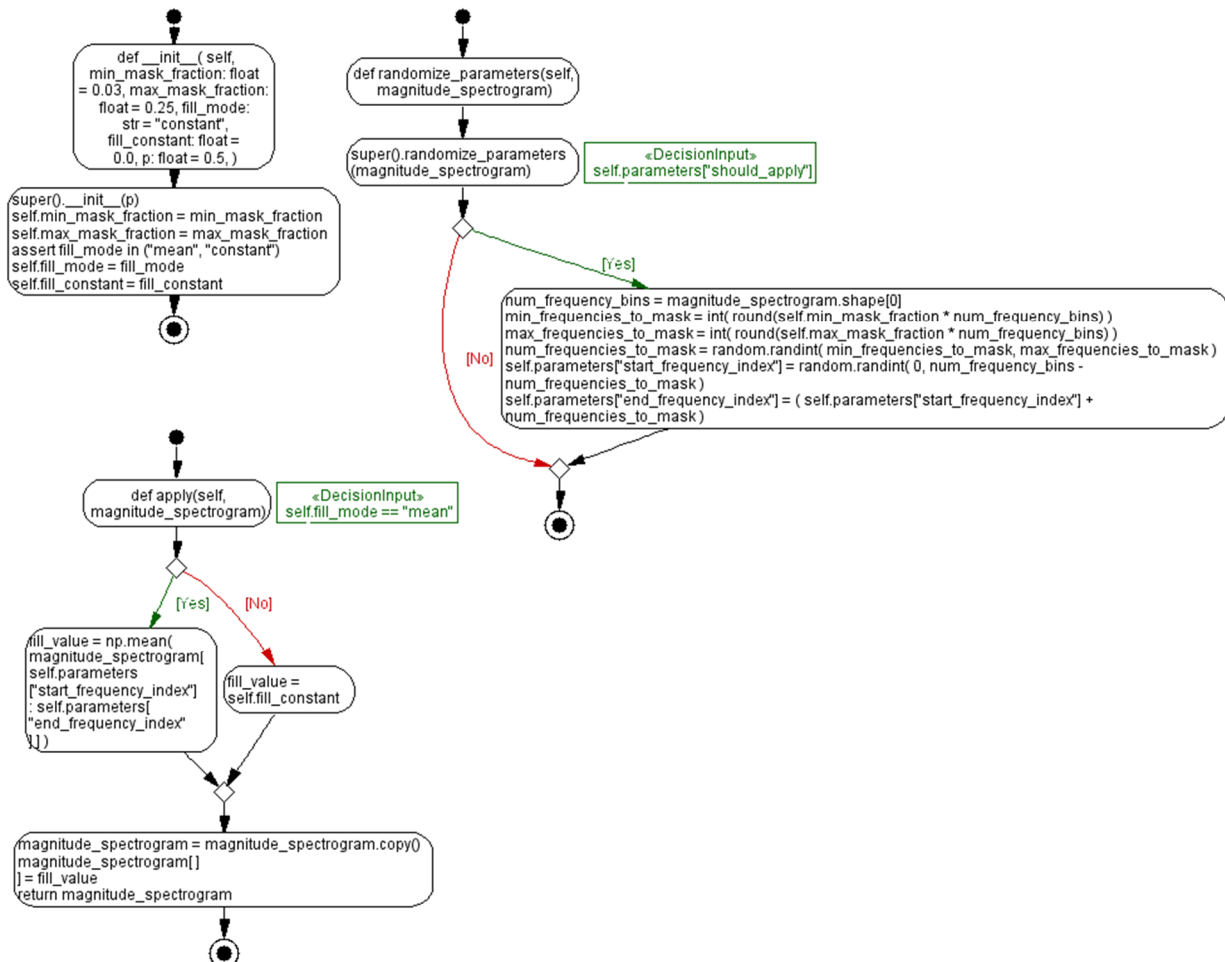


Рисунок 1 – Алгоритм случайного блокирования диапазона последовательных частот  
Figure 1 – Algorithm for random blocking of serial frequency range

Аугментации применительно к аудиоданным может осуществляться как на необработанном аудио перед созданием спектрограммы, так и на сгенерированной спектрограмме. Увеличение спектрограммы обычно дает лучшие результаты. Однако преобразования, которые были указаны выше для изображения, не применимы к спектрограммам. Например, поворот

на 20 градусов существенно изменит спектрограмму и звук, который она представляет. А это в свою очередь повлияет на значение метки класса аудиоданных.

Спектрограмма может помочь во время поиска неисправности оборудования, а также помочь оптимизировать и улучшить диагностику оборудования.

В данной работе ставится задача оценки метрик качества моделей классификации работоспособности оборудования, обученных на одних и тех же нейросетевых архитектурах с одними и теми же настроенными гиперпараметрами, но на разных датасетах: оригинальном и расширенном на основе предложенных подходов.

Для аугментации аудиоданных в работе предлагаются следующие подходы.

1. Заблокировать некоторые участки спектрограммы, т.е. реализовать случайную маскировку диапазона последовательных частот путем добавления горизонтальных полос на спектрограмму. Алгоритм данной процедуры представлен на рисунке 1. В алгоритме использованы функции из библиотеки аугментации от Iver Jordal [2].

2. Добавить гауссов шум к спектрограмме. Случайное отношение сигнал-шум в этом случае должно выбрано равномерно по шкале децибел. Это согласуется с человеческим слухом, который более логарифмический, чем линейный. Алгоритм данной процедуры представлен на рисунке 2.

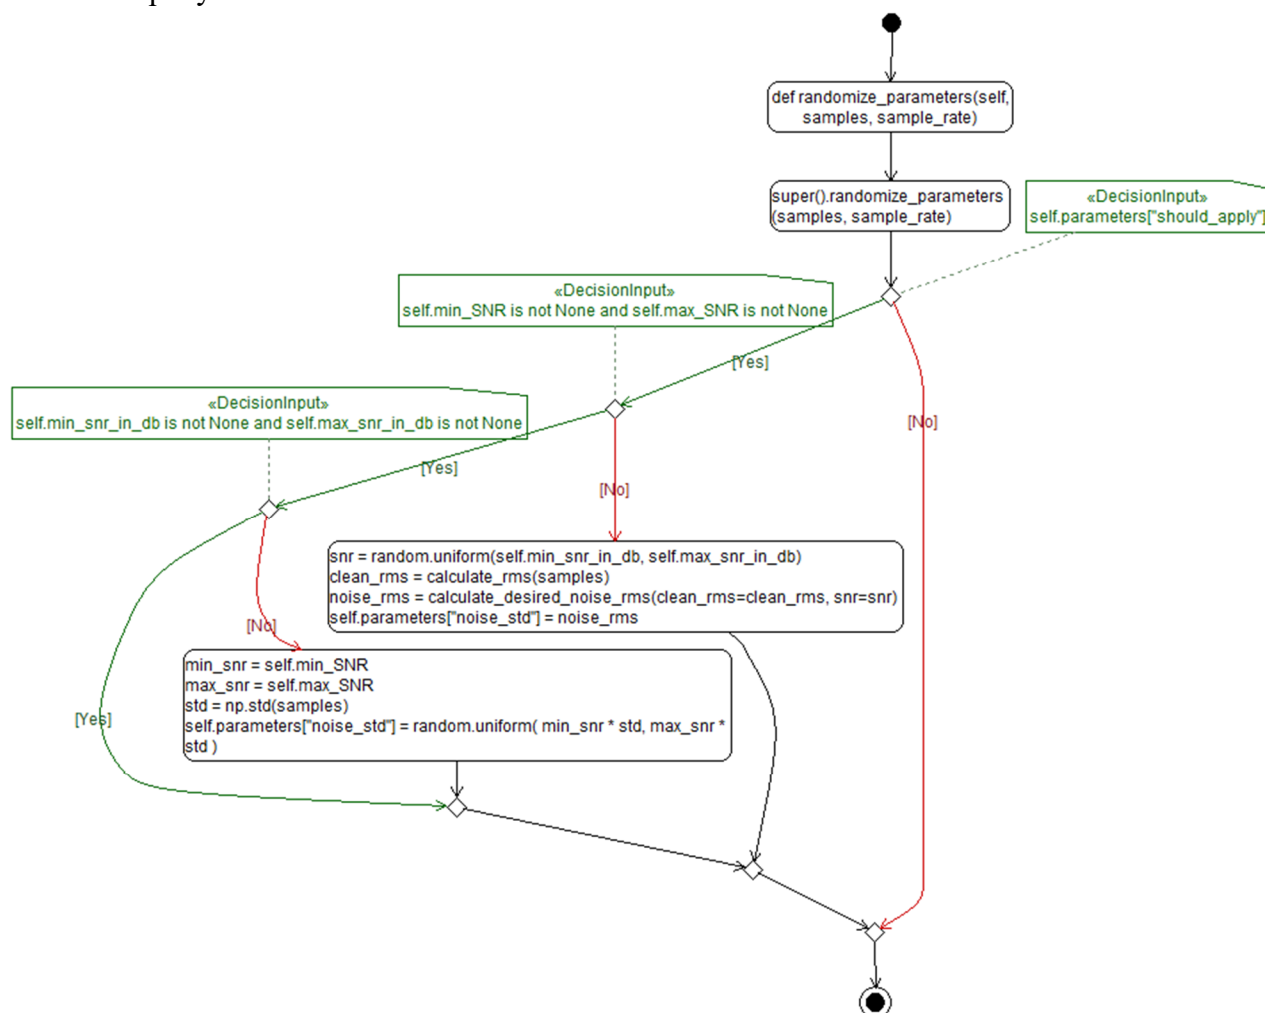


Рисунок 2 – Алгоритм добавления гауссова шума к спектрограмме, выравненного по шкале децибел

Figure 2 – Algorithm for adding decibel-aligned Gaussian noise to a spectrogram

Рассмотрим, как изменятся значения метрик качества моделей классификации работоспособности оборудования, обученных на одних и тех же нейросетевых архитектурах с од-

ними и теми же настроенными гиперпараметрами, но на разных датасетах: оригинальном и расширенном на основе выше предложенных подходов.

### Экспериментальные исследования

Оригинальный датасет был сформирован в результате аудиозаписи работы насосной станции AL-KO HW 3600 Easy 113798 на стадии проектирования киберфизического уровня ее цифровой копии. Насосная станция AL-KO HW 3600 Easy 113798 предназначена для откачивания грунтовых вод и перекачивания чистой воды. Технические данные станции представлены в таблице 1.


**Таблица 1 – Технические данные насосной станции AL-KO HW 3600 Easy 113798**

**Table 1 – Technical data of pump station AL-KO HW 3600 Easy 113798**

Мощность двигателя, Ватт	850
Диаметр приемного патрубка	G 1" (33,3 mm)
Давление выключения, Бар	2.8
Максимальная высота подачи, м	38
Максимальное давление, Бар	3.8
Привод насоса	1-ступенчатый
Объем сосуда под давлением, л	17
Датчик давления	Манометр
Диаметр нагнетательного провода	G 1" (33,3 мм)
Макс. напор всасывания, м	8
Максимальный расход, л/час	3600

Каждый объект датасета представляет собой 10-секундную аудиозапись с соответствующей меткой: нормальная работа, ненормальная работа


Первоначальный объем датасета составлял 314 объектов. На рисунке 3 представлена спектрограмма и график амплитуды одного из таких объектов с меткой «ненормальная работа».



**Рисунок 3 – Спектрограмма и график амплитуды оригинального аудио трека**

**Figure 3 – Spectrogram and amplitude plot of original audio track**

44 объекта были изменены путем блокировки частотных участков спектрограммы аудиотреков. Результат аугментации через случайную маскировку диапазона последовательных частот представлен на рисунке 4.




**Рисунок 4 – Результат аугментации аудиотрека путем случайной маскировки диапазона последовательных частот**

**Figure 4 – The result of augmenting an audio track by randomly masking the serial frequency range**

Еще 34 объекта были изменены путем добавления гауссова шума к спектрограмме с равномерным случайным отношением сигнал-шум по шкале децибел.

Результат такой аугментации представлен на рисунке 5.



**Рисунок 5 – Результат аугментации аудио трека путем добавления гауссова шума к спектрограмме с равномерным случайным отношением сигнал-шум по шкале децибел**

**Figure 5 – The result of augmenting an audio track by adding Gaussian noise to a spectrogram with uniform random signal-to-noise ratio on decibel scale**

В результате первоначальный набор данных был расширен до 392 объектов.

В таблице 2 представлены значения F-меры, взятой как основная метрика качества моделей классификации работоспособности оборудования.

Модели были обучены на разных датасетах: оригинальном и расширенном на основе выше предложенных подходов. Однако Transfer learning был реализован на одних и тех же настроенных гиперпараметрах следующих предобученных сетей: VGG 16, VGG 19, ResNet 50, ResNet 101, ResNet 152, DenseNet 121, DenseNet 161, DenseNet 169.

Как видно из таблицы, значения F-меры тестовой выборки после Transfer learning на расширенном наборе данных после аугментации на основе предложенных алгоритмов во всех случаях выше, что свидетельствует об их эффективности.

**Таблица 2 – Значения F-меры тестовой выборки после Transfer learning**  
**Table 2 – Values of F-measure of test sample after Transfer learning**

Предобученная нейронная сеть	F-мера тестовой выборки после Transfer learning	
	Аугментация (44 объекта через частотную маску, 34 объекта: гауссов шум)	Без аугментации данных
VGG 16	0,8773	0,8544
VGG 19	0,8778	0,8533
ResNet 50	0,8823	0,8592
ResNet 101	0,8849	0,8612
ResNet 152	0,8854	0,8623
DenseNet 121	0,8971	0,8742
DenseNet 161	0,8992	0,8753
DenseNet 169	0,8995	0,8761

### Заключение

В статье предложено два подхода к аугментации аудиоданных с киберфизического уровня цифровых двойников технологических систем: 1) алгоритм случайного блокирования диапазона последовательных частот, то есть блокировки некоторых участков спектрограммы; 2) добавление гауссова шума к спектрограмме.

Аугментация данных, полученных при работе насосной станции AL-KO HW 3600 Easy 113798 на стадии проектирования киберфизического уровня ее цифровой копии, позволила увеличить набор данных до 392 объектов.

Transfer learning был реализован на одних и тех же настроенных гиперпараметрах следующих предобученных сетей: VGG 16, VGG 19, ResNet 50, ResNet 101, ResNet 152, DenseNet 121, DenseNet 161, DenseNet 169. Значения F-меры тестовой выборки Transfer learning на расширенном наборе данных после аугментации на основе предложенных алгоритмов во всех случаях выше, чем на оригинальном наборе данных.

Данное исследование вносит определенный вклад в развитие использования нейронных сетей глубокого обучения к диагностике неисправностей оборудования. Предложенные методы позволят достичь высокой точности диагностики с небольшим исходным набором данных, а также решить проблему повышения безопасности и надежности эксплуатации технологической системы в реальных условиях.

### Библиографический список

1. **Дозорцев В. М.** Цифровые двойники в промышленности: генезис, состав, терминология, платформы, перспективы. Часть 2. Ключевые технологии цифровых двойников. Типы моделирования физического объекта // Автоматизация в промышленности. 2020. № 11. URL: <https://avtprom.ru/article/tsifrovyye-dvoyniki-v-promyshle-0>
2. **Audiomentations.** URL: <https://github.com/iver56/audiomentations>
3. **Ayani M., Ganebäck M., Ng A. H. C.** Digital Twin: Applying emulation for machine reconditioning. *Procedia Cirp*. 2018, vol. 72, pp. 243-248.
4. **Bai R. et al.** Rolling bearing fault diagnosis based on multi-channel convolution neural network and multi-scale clipping fusion data augmentation. *Measurement*. 2021, vol. 184, 109885 p.
5. **Li X. et al.** Intelligent rotating machinery fault diagnosis based on deep learning using data augmentation // *Journal of Intelligent Manufacturing*. 2020, vol. 31, no. 2, pp. 433-452.
6. **Mitiche I. et al.** Deep residual neural network for EMI event classification using bispectrum representations. 2018 26<sup>th</sup> European Signal Processing Conference (EUSIPCO). IEEE, 2018, pp. 186-190.



7. **Özcan E. et al.** An artificial neural network model supported with multi criteria decision making approaches for maintenance planning in hydroelectric power plants. *Eksploracja i Niezawodność*. 2020, vol. 22, no. 3.

UDC 004.896

## AUGMENTATION OF AUDIO DATA FROM CYBER-PHYSICAL LEVEL OF DIGITAL TWINS OF TECHNOLOGICAL SYSTEMS

**O. D. Kazakov**, Ph.D. (Econ.), Associate Professor, Vice-Rector for Digitalization, Head of the Department of IT, BGITU, Bryansk, Russia;

orcid.org/0000-0001-9665-8138, e-mail: it.kazakov@yandex.ru

**N. Yu. Azarenko**, Ph.D. (Econ.), Associate Professor, Master of BGITU, Bryansk, Russia;

orcid.org/0000-0001-6644-418X, e-mail: salovanat@mail.ru

*The problem of audio data augmentation from cyber-physical level of digital twins of technological systems is considered. The aim of the work is to evaluate quality metrics of equipment health classification models trained on the same neural network architectures with the same configured hyperparameters, but on different datasets: original and extended based on the proposed approaches: 1) random blocking algorithm for sequential frequency range, i.e. blockages of certain sections of the spectrogram; 2) adding Gaussian noise to the spectrogram. Augmentation of the data obtained during the operation of pumping station AL-KO HW 3600 Easy 113798 at the stage of designing the cyber-physical level of its digital copy made it possible to increase the data set to 392 objects. The values of F-measure of Transfer learning test set on the extended data set after augmentation based on the proposed algorithms are in all cases higher than on the original data set. This study makes a certain contribution to the increased application of deep learning neural networks for diagnosing equipment failures. The proposed methods will make it possible to achieve high diagnostic accuracy with a small initial data set, and also solve the problem of improving safety and reliability of technological system operation in real conditions.*

**Key words:** digital twin, technological system, audio data augmentation, cyber-physical level, transfer learning.

**DOI:** 10.21667/1995-4565-2022-80-127-133

### References

1. **Dozorcev V. M.** Cifrovye dvojniki v promyshlennosti: genezis, sostav, terminologiya, platformy, perspektivy. *CHast' 2. Klyuchevye tekhnologii cifrovyyh dvojnikov. Tipy modelirovaniya fizicheskogo ob"ekta Avtomatizatsiya v promyshlennosti*. 2020, no. 11. URL: <https://avtprom.ru/article/tsifrovye-dvojniki-v-promyshle-0> (in Russian).

2. **Audiomentations**. URL: <https://github.com/iver56/audiomentations>.

3. **Ayani M., Ganebäck M., Ng A. H. C.** Digital Twin: Applying emulation for machine reconditioning *Procedia Cirp*. 2018, vol.72, pp. 243-248.

4. **Bai R. et al.** Rolling bearing fault diagnosis based on multi-channel convolution neural network and multi-scale clipping fusion data augmentation *Measurement*. 2021, vol. 184, p. 109885.

5. **Li X. et al.** Intelligent rotating machinery fault diagnosis based on deep learning using data augmentation. *Journal of Intelligent Manufacturing*. 2020, vol. 31. no. 2, pp. 433-452.

6. **Mitiche I. et al.** Deep residual neural network for EMI event classification using bispectrum representations *2018 26<sup>th</sup> European Signal Processing Conference (EUSIPCO)*. IEEE, 2018, pp. 186-190.

7. **Özcan E. et al.** An artificial neural network model supported with multi criteria decision making approaches for maintenance planning in hydroelectric power plants *Eksploracja i Niezawodność*. 2020, vol. 22, no. 3.