

<https://doi.org/10.32603/2071-8985-2024-17-4-53-60>

## Спектральные характеристики сигналов для их классификации по уровню раздражительности методами машинного обучения

Д. В. Степура✉, Л. Г. Стаценко, А. Ю. Родионов

Дальневосточный федеральный университет, Владивосток, Россия

✉ stepura.dv@students.dvfu.ru

**Аннотация.** Популярность использования методов машинного обучения для классификации аудиосигналов растет с каждым годом: все большее значение приобретает распознавание качественных параметров шума, однако его негативное влияние изучается редко. Представлены методы определения раздражительности шума, которые могут быть полезны для создания систем, контролирующих зашумленность среды, и смогут оценивать не только акустические характеристики, но и эстетические, когнитивные эффекты, оказываемые шумом на человека. Приведено сравнение результатов работы нейронной сети по определению степени раздражительности шумов по психоакустическому параметру с использованием различных спектральных характеристик.

**Ключевые слова:** машинное обучение, нейронная сеть, психоакустическое раздражение, спектральные характеристики

**Для цитирования:** Степура Д. В., Стаценко Л. Г., Родионов А. Ю. Спектральные характеристики сигналов для их классификации по уровню раздражительности методами машинного обучения // Изв. СПбГЭТУ «ЛЭТИ». 2024. Т. 17, № 4. С. 53–60. doi: 10.32603/2071-8985-2024-17-4-53-60.

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

**Финансирование:** Работа выполнена в рамках государственного задания Минобрнауки России в сфере научной деятельности по проекту № FZNS-2023-0008.

Original article

## Spectral Characteristics of Signals for Their Classification According to the Level of Annoyance by Machine Learning Methods

D. V. Stepura✉, L. G. Statsenko, A. Yu. Rodionov

Far Eastern Federal University, Vladivostok, Russia

✉ stepura.dv@students.dvfu.ru

**Abstract.** The popularity of using machine learning methods to classify audio signals continues to grow. Although the recognition of qualitative parameters of noise is becoming increasingly important, its negative aspects have been rarely studied. Methods for determining the level of noise annoyance are presented. These methods can be useful for creating systems that control the noise level of the environment, as well as for evaluating not only acoustic characteristics, but also aesthetic and cognitive effects exerted by noise on a person. A comparison of the results of a neural network in determining the degree of noise annoyance in terms of the psychoacoustic parameter using various spectral characteristics is presented.

**Keywords:** machine learning, neural network, psychoacoustic annoyance, spectral characteristics

**For citation:** Stepura D. V., Statsenko L. G., Rodionov A. Yu. Spectral Characteristics of Signals for Their Classification According to the Level of Annoyance by Machine Learning Methods // LETI Transactions on Electrical Engineering & Computer Science. 2024. Vol. 17, no. 4. P. 53–60. doi: 10.32603/2071-8985-2024-17-4-53-60.

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

**Funding:** The work was carried out within the framework of the state assignment of the Ministry of Education and Science of the Russian Federation in the field of scientific activity on the project № FZNS-2023-0008.

**Введение.** Определение раздражительности шумов важно для того, чтобы понять, какие звуки могут негативно повлиять на здоровье и благополучие людей. Возможность определения степени негативного влияния звуков и шумов будет играть важную роль не только для сохранения здоровья человека, но также и для поддержания благоприятной природной обстановки.

Цель статьи состоит в исследовании алгоритмов методов машинного обучения для классификации сигналов по уровню раздражительности, используя различные спектральные признаки в качестве тренировочных данных.

Вследствие быстрого развития технологий и доступности больших объемов данных использование методов машинного обучения становится все более популярным. Реализуемые искусственные нейронные сети (ИНС) имитируют активность нейронов головного мозга, что на практике дает ряд преимуществ по сравнению с традиционными подходами [1]. Такой метод позволяет одновременно учитывать большое число параметров, влияющих на многие зависимые переменные, автоматически создавать аналитические модели высокой сложности на основе приведенных баз данных, которые способны в достаточной степени отражать присущие исследуемой структуре причинно-следственные связи между характеристиками. Кроме того, можно автоматически оценивать, насколько каждый из воздействующих параметров влияет на зависимые величины, и исправлять расчетную аналитическую модель при добавлении новых данных посредством «доучивания» нейросети.

Глубокое обучение – это отрасль машинного обучения, которая заставляет компьютеры делать то, что естественно для людей: учиться на собственном опыте. Модели глубокого обучения позволяют достичь самой современной точности классификации объектов, иногда превышающей производительность человека.

**Построение модели машинного обучения.** Моделирование систем при помощи ИНС происходит в три этапа: первый – обучение, второй – оценка результатов обучения, и третий – использование обученной сети для прогнозирования.

На этапе обучения в нейросеть подается большой объем данных – образцов с известными

характеристиками, и она проходит через множество итераций обучения, оптимизируя на каждой из них свои параметры и настраивая связи между нейронами, чтобы достичь наилучшего результата, т. е. происходит подгонка сети корректировкой весовых коэффициентов нейронов в соответствии с ошибкой на выходе. Для проверки работоспособности на каждом шаге обучения сети рассчитывается ошибка для всего набора наблюдений из контрольного множества и сравнивается с ошибкой на обучающем множестве [2].

После завершения обучения нейросеть переходит в режим применения, где она используется для выявления паттернов и закономерностей в новых незнакомых данных, которые могут не содержать сведений о конкретных характеристиках.

Для решения различных задач по оценке звуковых сигналов активно применяются многослойные сверточные нейронные сети (Convolutional Neural Networks – CNN), которые используются в компьютерном зрении для распознавания изображений, видео или звуковых сигналов. Она основана на идее свертки – технике обработки изображений, которая позволяет выделять важные признаки (например, края, формы) и фильтровать шумы. Свойства сверточных слоев сети позволяют выявлять низкоуровневые признаки на первых слоях, а затем более высокоуровневые свойства в последних слоях [3].

Использование нейросетей для распознавания шумов позволяет автоматизировать и упростить процесс анализа шумовых данных, что особенно полезно в ситуациях, когда требуется обработка большого объема данных или быстрая реакция на изменение шумовой ситуации. ИНС обучается таким образом, чтобы минимизировать ошибку на ее выходе, определяемую при помощи различных статистических показателей, например средней абсолютной ошибки. Сеть, имеющая наименьшую ошибку, считается наиболее эффективной.

Для анализа сигналов и выполнения экспериментов использовалась прикладная программа MatLab, с помощью которой была решена задача классификации созданием простой сетевой архитектуры в виде массива уровней. Использовались слои сверточной и пакетной нормализации, а также слои максимального объединения. Чтобы

уменьшить вероятность запоминания сетью специфических характеристик обучающих данных, на вход последнего полностью подключенного уровня добавляется специальный слой «dropout» для предотвращения переобучения нейросети. Всего в сети пять сверточных слоев. Такой тип сети часто применяется в анализе визуальных образов, а значит, должен показать удовлетворительные результаты классификации изображений спектрограмм разного типа.

**Сортировка тестируемых данных.** При решении задач классификации часто используется контролируемое обучение (с учителем), т. е. входные тренировочные данные должны быть заранее отсортированы по категориям, в данном случае по степени раздражительности. В качестве исследуемого датасета звуковых сигналов выступала коллекция из 2000 звуковых отрывков, представляющих собой открытую библиотеку ESC-50 [4].

Негативное влияние шума на человека нельзя в полной мере описать только уровнем интенсивности звука, так как этого параметра будет недостаточно, поэтому для оценки раздражительности были рассчитаны специальные психоакустические характеристики – громкость, резкость, сила флуктуаций и хриплость – для всех 2000 отрывков шумов [5]. На основе этих показателей для каждого сигнала было вычислено значение психоакустического раздражения (ПАР), которое и определяет сортировку образцов шума [6]. Для подтверждения достоверности полученных значений ПАР была проведена слуховая экспертиза, которая доказала приемлемость выбранного метода вычисления ПАР.

Процесс обучения нейросети для распознавания начинается с набора данных, которые будут

использоваться для обучения. В качестве датасета для распознавания степени раздражительности звуков были сформированы 4 группы по 40 аудиосигналов, количественное распределение которых показано на рис. 1, где в каждой из групп находятся шумы разного происхождения с уровнем ПАР в определенном диапазоне. Таким образом были сформированы четыре категории сигналов:

группа 1 – сигналы с низким уровнем раздражительности (значение ПАР от 5 до 20);

группа 2 – со средним уровнем раздражительности (значение ПАР от 35 до 45);

группа 3 – сигналы с высоким уровнем раздражительности (значение ПАР от 60 до 75);

группа 4 – сигналы с очень высоким уровнем раздражительности (значение ПАР от 90 до 120).

Все данные разделяются на две группы – тренировочную и тестовую. Тренировочный набор данных используется для обучения нейросети (пусть это 80 % от каждого класса представленных сигналов), тестовый – для оценки ее точности (тестируются остальные 20 % сигналов).

**Обработка сигналов.** Для обучения нейросети на аудиосигналах необходимо провести некоторые подготовительные процедуры, чтобы получить корректные тренировочные экземпляры и подходящие отличительные признаки. Предварительная обработка данных включает в себя такие операции, как преобразование частоты дискретизации (если это необходимо), выравнивание длины звуковых сегментов, применение методов защиты от шума – фильтрации и удаления артефактов.

Далее необходимо извлечь признаки из сигналов, так как классификация по осциллограмме крайне низкоэффективна. Обычно для классифи-

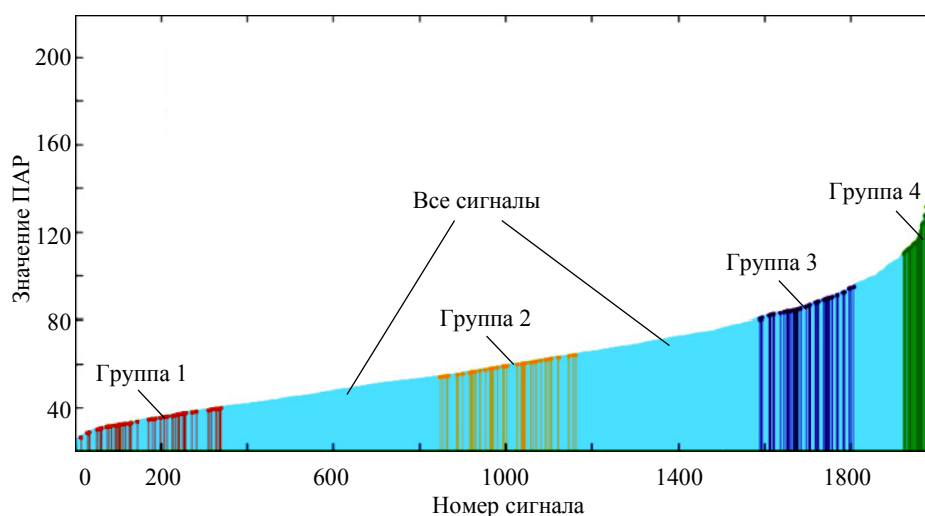


Рис. 1. Объединение аудиосигналов с примерно одинаковым ПАР в группы  
Fig. 1. Combining audio signals with approximately the same PA into groups

кации и анализа акустических сигналов или шумов извлекаются спектральные или кепстральные признаки, но они могут варьироваться в зависимости от конкретной задачи, поставленной перед нейросетью. Для анализа звуковых сигналов с помощью сверточных нейронных сетей необходимо конвертировать полученные признаки в изображение, поэтому часто рассматриваются спектрограммы, которые показывают, как энергия звуковой волны распределена по частотам в зависимости от времени [7].

Одним из возможных представлений сигнала служит линейная спектрограмма, которая представляет частотный спектр сигнала в виде матрицы, где значения цвета ячеек (или их оттенки) отражают уровень звукового давления в данный момент времени и на данной частоте. На линейной шкале частоты распределены равномерно. Линейная шкала позволяет более точно отображать высокие частоты сигнала, поскольку она сохраняет одинаковое расстояние между соседними отсчетами.

Однако для анализа звуковых сигналов в нейронных сетях более удобна мел-спектрограмма. Для ее создания спектрограмма преобразуется из линейной шкалы частот в логарифмическую. Этот переход происходит с помощью функции преобразования мел-шкалы.

Мел-шкала представляет собой шкалу, разработанную на основе структуры человеческого слуха. Она учитывает, что наше восприятие звуков меняется нелинейно в зависимости от частоты и отделяет более информативные низкие частоты от менее информативных высоких. На рис. 2 показан пример мел-спектрограммы сигнала треска сверчков.

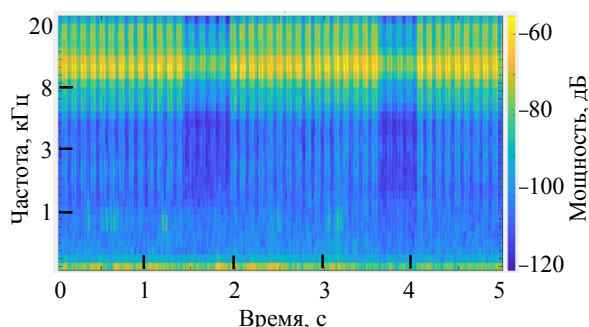


Рис. 2. Пример мел-спектрограммы сигнала треска сверчков

Fig. 2. Example of a mel-spectrogram of a cricket noise signal

Помимо мел-шкалы существует шкала Барка, которая также относится к логарифмическим и позволяет более точно анализировать спектр звуков в контексте человеческого слуха. Шкала Бар-

ка разбивает частоты на равные интервалы, воспринимаемые человеческим ухом как одинаково значимые. Она позволяет моделировать характеристики человеческого слуха на основе высот звуков [8].

Таким образом, барк-спектрограммы могут быть более эффективны для обработки звуковых сигналов, связанных с распознаванием речи и звука. На рис. 3 показан пример барк-спектрограммы сигнала треска сверчков. Предлагается в качестве отличительных признаков использовать именно изображение мел- и барк-спектрограмм.




Рис. 3. Пример барк-спектрограммы сигнала треска сверчков

Fig. 3. Example of a bark-spectrogram of a cricket noise signal

**Оценка результатов работы нейросети.** Для анализа качества работы нейросети существуют различные метрики. Они определяют, насколько точно нейронная сеть предсказывает значения выходных данных на основе входных данных. В качестве метрик для оценки работы данной нейросети использованы:

- 1) Accuracy (точность) – наиболее распространенная метрика, которая измеряет долю правильных ответов, полученных нейросетью;
- 2) Recall (полнота) – метрика, измеряющая долю корректно идентифицированных экземпляров, которые были ложноположительно классифицированы как негативные образцы;
- 3) Precision (точность) – метрика, которая измеряет долю правильно идентифицированных экземпляров, среди всех предсказанных положительных образцов;
- 4) F1 Score – гармоническое среднее между точностью и полнотой, принимающее значения от 0 до 1, где 1 означает наилучшую метрику [9].

Для наглядного представления результатов тестирования нейросетей используются матрицы ошибок – таблицы, необходимые для оценки качества работы алгоритмов машинного обучения.




Рис. 4. Матрицы ошибок при проверке сети, обученной на классификацию сигналов по значению ПАР по барк-спектрограмме (а) и по мел-спектрограмме (б)

Fig. 4. Confusion matrices for network trained to classify signals by the value of PA using the bark-spectrogram (a) and the mel-spectrogram (b)

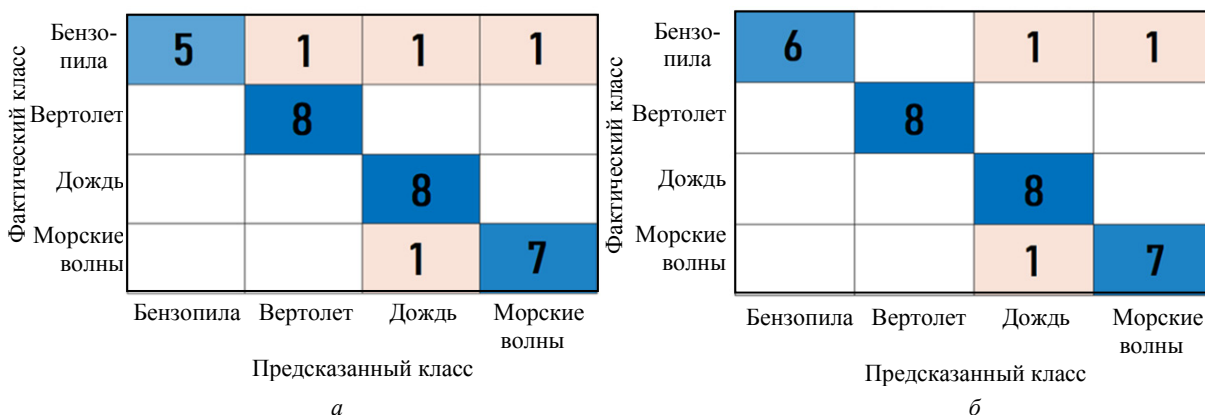


Рис. 5. Матрицы ошибок при проверке сети, обученной на классификацию сигналов по источнику шума по барк-спектрограмме (а) и по мел-спектрограмме (б)

Fig. 5. Confusion matrices for network trained to classify signals by noise source using the bark-spectrogram (a) and the mel-spectrogram (b)

Табл. 1. Результаты тренировок сетей  
Tab. 1. Network training results

| Признак сортировки    | Тип признака | Accuracy, % | Recall, % |      | Precision, % |     | F1 Score, % |
|-----------------------|--------------|-------------|-----------|------|--------------|-----|-------------|
|                       |              |             | min       | max  | min          | max |             |
| Определение источника | Мел          | 90.63       | 75.0      | 100  | 87.5         | 100 | 91.25       |
|                       | Барк         | 87.50       | 62.5      | 100  | 80.0         | 100 | 88.29       |
| Определение ПАР       | Мел          | 71.88       | 62.5      | 87.5 | 55.6         | 100 | 73.7        |
|                       | Барк         | 68.75       | 50.0      | 87.5 | 50.0         | 100 | 71.0        |

Матрица ошибок представляет собой квадратную таблицу, где строки соответствуют фактическому классу объектов, а столбцы – предсказанному классу. Значения в ячейках матрицы показывают, сколько объектов было правильно или неправильно классифицировано.

Далее рассмотрены результаты работы алгоритма на предмет классификации сигналов по их уровню ПАР. На рис. 4 показаны матрицы ошибок распознавания сигналов по барк- и мел-спектрограммам. Значения метрик оценки показаны в табл. 1.

Полученные результаты трудно оценить объективно, поэтому для сравнения была проведена классификация сигналов по качественному признаку, т. е. решена распространенная задача распознавания источника звука с помощью той же нейросети и на основе тех же признаков.

Для тренировки нейросети по задаче качественной классификации сигналов были отобраны шумы четырех типов: звуки бензопилы, морских волн, дождя и вертолета. Общее количество данных равно 160, где на каждый тип приходится по 40 сигналов, т. е. количество испытуемых данных совпадает с предыдущим экспериментом.

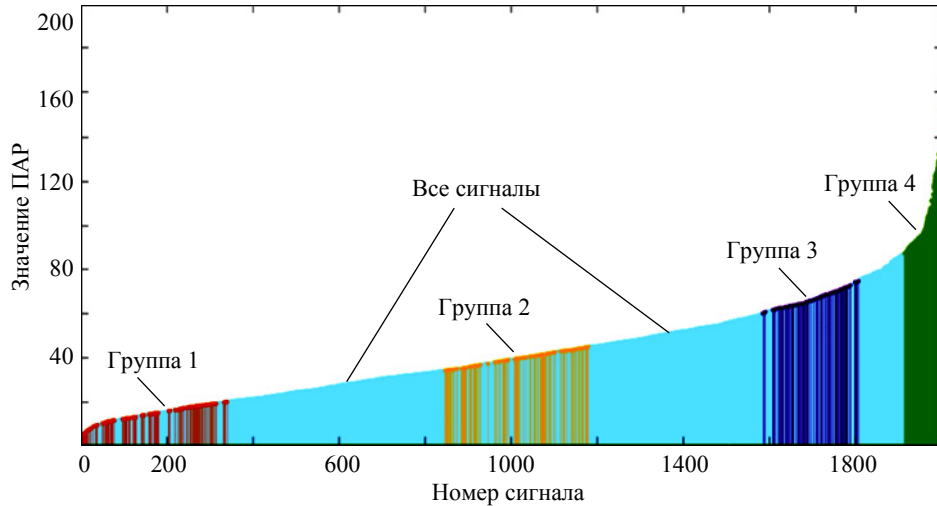


Рис. 6. Объединение аудиосигналов с примерно одинаковым ПАР в группы с увеличенным количеством сигналов  
Fig. 6. Combining audio signals with approximately the same PA into groups with an increased number of signals




Рис. 7. Матрицы ошибок при проверке сети, обученной на классификацию сигналов по значению ПАР по барк-спектрограмме (а) и по мел-спектрограмме (б) при увеличенных входных данных  
Fig. 7. Confusion matrices for network trained to classify signals by the value of PA using the bark-spectrogram (a) and the mel-spectrogram (b) with increased input data

Табл. 2. Результаты тренировок сети по определению ПАР  
Tab. 2. Results of network training to determine PA

| Количество тренировочных данных | Тип признака | Accuracy, % | Recall, % |      | Precision, % |      | F1 Score, % |
|---------------------------------|--------------|-------------|-----------|------|--------------|------|-------------|
|                                 |              |             | min       | max  | min          | max  |             |
| 128                             | Мел          | 71.88       | 62.5      | 87.5 | 55.6         | 100  | 73.7        |
|                                 | Барк         | 68.75       | 50.0      | 87.5 | 50.0         | 100  | 71.0        |
| 256                             | Мел          | 79.69       | 62.5      | 87.5 | 72.2         | 100  | 80.19       |
|                                 | Барк         | 76.56       | 62.5      | 93.8 | 62.5         | 93.8 | 76.86       |

Результаты работы сети, которая обучена классифицировать сигналы по источнику шума, показаны на рис. 5 и в табл. 1.

Анализируя полученные результаты, можно сделать вывод, что при одинаковом количестве входных данных и одинаковых настройках модели алгоритма машинного обучения нейросеть справляется с классификацией аудиосигналов по источнику звука лучше, чем с определением уровня ПАР. Также видно, что использование мел-спектрограмм в

качестве обучающего признака дает более точные предсказания в обоих случаях.

Для повышения точности работы нейросети без изменения ее структуры можно увеличить количество тренировочных данных. Пусть теперь в каждой из 4 групп с примерно одинаковым ПАР будет 80 сигналов (рис. 6). Результаты обучения с увеличенным количеством данных показаны на рис. 7 и в табл. 2.

При увеличении входных тренировочных данных значительно увеличивается показатель Ассигасы, что говорит об увеличении количества верных попаданий, также увеличились минимальные показатели Recall и Precision. Тем не менее, даже при увеличении входных данных показатели сети по классификации сигналов по источнику звука все еще выше, что говорит о низкой пригодности спектральных признаков для распознавания степени ПАР.

**Заключение.** Использованный метод машинного обучения – сверточная нейронная сеть – менее пригоден для определения раздражительности звуков, нежели для классической классификации сигналов по их источнику, если для обучения нейросети используются спектральные характеристики. Данное наблюдение указывает на уникальность психоакустических признаков сигнала, что

говорит о необходимости их использования для оценки влияния звуков и шума на человека.

Таким образом, классификация сигналов по уровню их раздражительности достаточно трудна. Для повышения качества результатов можно изменить структуру нейросети на более сложную либо, если стоит задача интегрировать такого рода распознавание в уже имеющуюся сеть, необходимо использовать иные характеристики сигнала или их совокупность для более точных предсказаний.

Дальнейшие исследования в данной области могут быть полезны для оценки и выявления негативного воздействия звуков на человека в любой сфере его деятельности, так как раздражительный фоновый шум влияет на самочувствие и настроение человека, что снижает его работоспособность и ухудшает здоровье.

#### Список литературы

- Günter F., Fritsch S. Neuralnet: Training of neural networks // The R J. 2010. № 2(1). P. 30–38.
- Krizhevsky A., Sutskever I., Hinton G. E. Imagenet classification with deep convolutional neural networks // Proc. of the 25<sup>th</sup> Intern. Conf. on Neural Information Proc. Systems (NIPS12). 2012. Vol. 1. P. 1097–1105. URL: <https://proceedings.neurips.cc/paper/2012/file/c399862d369d6b76c8436e924a68c45b-Paper.pdf> (дата обращения 07.11.2023).
- Zhang H., McLoughlin I., Song Y. Robust sound event recognition using convolutional neural networks // IEEE Intern. Conf. on Acoustics, Speech and Signal Proc. (ICASSP). South Brisbane, QLD, Australia: IEEE, 2015. P. 559–563.
- Piczak K. J. ESC: Dataset for environmental sound classification // Proc. of the 23<sup>rd</sup> ACM Intern. Conf. on Multimedia. New York, NY, United States: ACM, 2015.
- Римская-Корсакова Л. К., Пятаков П. А., Шуляпов С. А. Оценки раздражающего действия шума // Акустический журн. 2022. Т. 68, № 5. С. 550–561. doi: 10.31857/S0320791922050100.
- Fastl H., Zwicker E. Psychoacoustics: Facts and models. Berlin Heidelberg: Springer, 2007.
- Степура Д. В., Миргородская Ю. В., Кузин Д. А. Исследование признаков акустических сигналов для их классификации методами машинного обучения // Сб. мат. 65-й Всерос. научн. конф. Т. 3. Владивосток: Тихоокеанское высшее военно-морское училище им. С. О. Макарова Минобороны РФ, 2022. С. 293–299.
- Spoken language identification using hybrid feature extraction methods / P. Kumar, A. Biswas, A. N. Mishra, M. Chandra // J. of Telecommunications. 2010. Vol. 1, iss. 2.
- Применение методов машинного обучения для классификации акустических сигналов по спектральным характеристикам / Д. А. Кузин, Л. Г. Стаценко, П. Н. Анисимов, М. М. Смирнова // Изв. СПбГЭТУ «ЛЭТИ». 2021. № 3. С. 48–54.

#### Информация об авторах

**Степура Диана Валериевна** – магистрант Дальневосточного федерального университета, п. Аякс, 10, о. Русский, Владивосток, Приморский край, 690922, Россия.  
E-mail: [stepura.dv@dvfu.ru](mailto:stepura.dv@dvfu.ru)

**Стаценко Любовь Григорьевна** – д-р физ.-мат. наук, профессор, директор Департамента электроники, телекоммуникации и приборостроения Политехнического института Дальневосточного федерального университета, п. Аякс, 10, о. Русский, Владивосток, Приморский край, 690922, Россия.  
E-mail: [statsenko.lg@dvfu.ru](mailto:statsenko.lg@dvfu.ru)  
<https://orcid.org/0000-0001-7498-9534>

**Родионов Александр Юрьевич** – д-р техн. наук, профессор департамента электроники, телекоммуникации и приборостроения Политехнического института Дальневосточного федерального университета, п. Аякс, 10, о. Русский, Владивосток, Приморский край, 690922, Россия.  
E-mail: [rodionov.ayur@dvfu.ru](mailto:rodionov.ayur@dvfu.ru)  
<https://orcid.org/0000-0003-2931-900X>

## References

1. Günter F., Fritsch S. Neuralnet: Training of neural networks // The R J. 2010. № 2(1). P. 30–38.
2. Krizhevsky A., Sutskever I., Hinton G. E. Imagenet classification with deep convolutional neural networks // Proc. of the 25<sup>th</sup> Intern. Conf. on Neural Information Proc. Systems (NIPS12). 2012. Vol. 1. P. 1097–1105. URL: <https://proceedings.neurips.cc/paper/2012/file/c399862d369d6b76c8436e924a68c45b-Paper.pdf> (data obrashchenija 07.11.2023).
3. Zhang H., McLoughlin I., Song Y. Robust sound event recognition using convolutional neural networks // IEEE Intern. Conf. on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane, QLD, Australia: IEEE, 2015. P. 559–563.
4. Piczak K. J. ESC: Dataset for environmental sound classification // Proc. of the 23<sup>rd</sup> ACM Intern. Conf. on Multimedia. New York, NY, United States: ACM, 2015.
5. Rimskaja-Korsakova L. K., Pjatakov P. A., Shuljapov S. A. Ocenki razdrazhajushhego dejstvija shuma // Akusticheskij zhurn. 2022. T. 68, № 5. S. 550–561. doi: 10.31857/S0320791922050100. (In Russ.).
6. Fastl H., Zwicker E. Psychoacoustics: Facts and models. Berlin Heidelberg: Springer, 2007.
7. Stepura D. V., Mirgorodskaja Ju. V., Kuzin D. A. Issledovanie priznakov akusticheskikh signalov dlja ih klasifikacii metodami mashinnogo obuchenija // Sb. mat. 65-j Vseros. nauchn. konf. T. 3. Vladivostok: Tihookeanskoe vysshee voenno-morskoe uchilishhe imeni S. O. Makarova Minoborony RF, 2022. S. 293–299. (In Russ.).
8. Spoken language identification using hybrid feature extraction methods / P. Kumar, A. Biswas, A. N. Mishra, M. Chandra // J. of Telecommunications. 2010. Vol. 1, iss. 2.
9. Primenenie metodov mashinnogo obuchenija dlja klassifikacii akusticheskikh signalov po spektral'nym karakteristikam / D. A. Kuzin, L. G. Stacenko, P. N. Anisimov, M. M. Smirnova // Izv. SPbGJeTU «LJeTI». 2021. № 3. S. 48–54. (In Russ.).

---

## Information about the authors

**Diana V. Stepura** – Master's student of the Far Eastern Federal University, 10 Ajax Bay, Russky Island, Vladivostok, Primorsky Krai, 690922, Russia.  
E-mail: [stepura.dv@dvfu.ru](mailto:stepura.dv@dvfu.ru)

**Lyubov G. Statsenko** – Dr Sci. (Phys.-Math.), Professor, Director of the Department of Electronics, Telecommunications and Instrumentation of the Polytechnic Institute of the Far Eastern Federal University, 10 Ajax Bay, Russky Island, Vladivostok, Primorsky Krai, 690922, Russia.  
E-mail: [statsenko.lg@dvfu.ru](mailto:statsenko.lg@dvfu.ru)  
<https://orcid.org/0000-0001-7498-9534>

**Aleksandr Yu. Rodionov** – Dr Sci., Professor of the Department of Electronics, Telecommunications and Instrumentation of the Polytechnic Institute of the Far Eastern Federal University, 10 Ajax Bay, Russky Island, Vladivostok, Primorsky Krai, 690922, Russia.  
E-mail: [rodionov.ayur@dvfu.ru](mailto:rodionov.ayur@dvfu.ru)  
<https://orcid.org/0000-0003-2931-900X>

Статья поступила в редакцию 21.12.2023; принята к публикации после рецензирования 20.02.2024; опубликована онлайн 23.04.2024.

Submitted 21.12.2023; accepted 20.02.2024; published online 23.04.2024.

---