

ТЕХНИКА И РЕЗУЛЬТАТЫ АНАЛИЗА ШУМА ДЕРЕВООБРАБАТЫВАЮЩЕГО ОБОРУДОВАНИЯ С ИСПОЛЬЗОВАНИЕМ ИСКУССТВЕННОЙ НЕЙРОСЕТИ

*Бедоидзе М.В., Богданец Д.А., Лесной Е.В., Отраднов К.В., Степаницын А.С.,
Харахашьян А.М.*

Донской государственный технический университет, Ростов-на-Дону

Ключевые слова: деревообрабатывающее оборудование, звуковое поле, спектральный анализ, Фурье-преобразование, нейронная сеть, достоверность распознавания.

Аннотация. Разработка нейронной сети для распознавания шума деревообрабатывающих инструментов при помощи звуковой карты ПК. Объектом анализа служили аудиотреки, отвечающие шуму различного технического оборудования. Сконструированные математические модели и реализующая нейросеть позволяет оперативно оценивать акустические характеристики различных производств. Результативность квантификации шумовой обстановки при помощи разработанных средств и методик подтверждена контрольными испытаниями.

NOISE ANALYSIS WITH RESPECT TO WOODWORKING EQUIPMENT BY MEANS OF AN ARTIFICIAL NEURAL NETWORK

*Bedoidze M.V., Bogdanets D.A., Lesnoy E.V., Otradnov K.V., Stepanitsyn A.S.,
Kharakhashyan A.M.*

Don State Technical University, Rostov-on-Don

Keywords: woodworking equipment, sound field, spectral analysis, Fourier transform, neural network, trustiness probability.

Аннотация. Development of a neural network for recognizing the noise of woodworking tools using a PC sound card. The object of the analysis was audio tracks corresponding to the noise of various technical equipment. The constructed mathematical models and the implementing neural network make it possible to quickly assess the acoustic characteristics of various industries. The effectiveness of quantification of the noise environment using the developed tools and techniques has been confirmed by control tests.

Актуальность данного исследования заключается в том, что опасность и вред здоровью работников от шумов технологического оборудования [1]. Механообрабатывающее оборудование, в том числе деревообрабатывающее особо шумное и травмоопасное. Предварительный анализ и квантификация опасности служит основой для принятия грамотных технических решений. Особую роль в таком анализе играют математические методы и технологии искусственного интеллекта [2]. Поэтому объект (деревообрабатывающее оборудования), его предмет (шумность) и цель исследования (разработка математических методов и средств диагностики акустической обстановки при помощи нейронной сети) представляются безусловно актуальными. Реализация цели исследования достигается путем решения следующих задач: 1) сбора достаточного числа аудиообразцов звукового поля, 2) их спектрального анализа, 3) систематизации результатов при помощи нейросети надлежащей конфигурации, 4) проверки предложенной технологии на предмет скорости и успешности обучения и ошибочности в распознавании.

Для выполнения исследования проводились записи звукового поля деревообрабатывающих инструментов (болгарки, дрели, шлифовального аппарата и т.д.). Аудиозапись проводилась в формате WAV с частотой дискретизации 44,1 кГц. Это обеспечило высокое качество звука и точное представление спектральных характеристик.

Далее проводился спектральный анализ записей акустического поля различного деревообрабатывающего оборудования (рис. 1).




Рис. 1. Использование Фурье-преобразования к звуку работы: а) болгарки; б) дрели без нагрузки; в) дрели; г) сварочного аппарата; д) воздушного компрессора; е) шлифовального аппарата

Анализируя полученные результаты, отметим максимальную амплитуду записей работы болгарки, дрели (с нагрузкой и без), сварочного аппарата, воздушного компрессора и шлифовального аппарата, которая составила {0,0011; 0,0013; 0,017; 0,0027; 0,0175; 0,0035} соответственно.

Рассматривая графики каждого инструмента можно отметить следующее.

1. В случае болгарки виден размах частот различной мощности, что говорит о сложности звука, который возникает вследствие быстрого вращения инструмента (рис. 1, а).

2. В случае дрели стоит отметить, что на холостом ходу (рис. 1, б) более выражены пики на высокой частоте по сравнению с нагрузкой на оборудование (рис. 1, в).

3. График работы сварочного аппарата (рис. 1, г) похож на работу болгарки (рис. 1, а), но различаются мощностью и расположением пиков.

4. График работы воздушного компрессора (рис. 1, д) сосредоточен в низкочастотном диапазоне, это объясняется циклами компрессии воздуха в результате работы оборудования.

5. Основная часть шума от шлифовального аппарата появляется в результате контакта шлифовального круга с обрабатываемой поверхностью, поэтому на графике (рис. 1, е) видна концентрация частот на низком уровне.

Как свидетельствуют экспериментальные спектрограммы на рисунке 1, все анализируемые на предмет шумности инструменты характеризуются частотным спектром с ярко выраженными пиками. Это обстоятельство позволяет использовать данные аудиозаписи для программной разработки с использованием искусственных нейросетей [3].

Проект реализован на языке программирования Python и объединяет следующие блоки программного кода.

1. Импорт необходимых библиотек и загрузка аудиозаписей шума деревообрабатывающего оборудования (использовались 7 файлов записи болгарки, 6 файлов записи холостого хода дрели, 8 записей дрели с нагрузкой, 8 файлов сварочного аппарата, 6 файлов холостого хода бензопилы, 7 файлов работающей бензопилы, 7 записей воздушного компрессора и 6 записей шлифовального аппарата).

2. Обработка исходного набора данных и подготовка к дальнейшему исследованию (аудиофайлы преобразуются в массивы данных, которые будут использоваться для обучения модели; рассчитываются количество фрагментов (длину массива) данных для каждой аудиозаписи; длина фрагмента (временного блока) задается как 4096 выборок, к которой будет применено Фурье-преобразование; каждому аудиофайлу присваивается определенная метка, которая указывает на его класс (тип оборудования));

3. Фурье-преобразование (применяется для того, чтобы перейти из временной области в частотную, т.к. это помогает обнаружить частотные компоненты сигнала для распознавания шума разного оборудования)

4. Генерация тестовых выборок для обучения нейросети.

5. Создание сверточной нейронной сети (рис. 2) (структура разработанной модели представлена на рис. 3 и содержит 12 слоев).

6. Компиляция и тренировка модели. В данном блоке для анализа процесса обучения модели используются:

– функция потерь, отвечающая отличию двух последовательных распределений:

$$Loss = -\frac{1}{N} \sum_{i=1}^N \ln(p_{y_i}), \quad (1)$$

где N – количество классов, p_{y_i} – вероятность, присвоенная правильному классу для i выборки.

– оптимизатор, позволяющий ускорить обучение нейросети, а также усовершенствовать метрику количественной оценки правильности предсказаний:

$$Accuracy = \frac{1}{N} \sum_{i=1}^N \delta_{\frac{y'_i}{y_i}, 1}, \quad (2)$$

где N – число примеров, y'_i – предсказанный класс для i примера, y_i – истинная метка для i примера, $\delta_{i,k}$ – символ Кронекера.

```
# Определение количества классов и формы входных данных
NUM_CLASSES = len(np.unique(y_data))
INPUT_SHAPE = (x_data.shape[1], x_data.shape[2])

# Параметры модели нейронной сети
def build_model():

    # Входной слой
    inputs = keras.Input(shape=INPUT_SHAPE)
    x = inputs

    # Первый сверточный блок
    x = keras.layers.Conv1D(256, 3, padding="same", data_format="channels_last")(x)
    x = keras.layers.BatchNormalization()(x)
    x = keras.layers.ReLU()(x)

    # Второй сверточный блок
    x = keras.layers.Conv1D(32, 3, padding="same", data_format="channels_last")(x)
    x = keras.layers.BatchNormalization()(x)
    x = keras.layers.ReLU()(x)

    # Третий сверточный блок
    x = keras.layers.Conv1D(4, 3, padding="same", data_format="channels_last")(x)
    x = keras.layers.BatchNormalization()(x)
    x = keras.layers.ReLU()(x)

    # Слой преобразования многомерного выхода в одномерный вектор и выходной слой
    x = keras.layers.Flatten()(x)
    outputs = keras.layers.Dense(NUM_CLASSES, activation="softmax")(x)
    return keras.Model(inputs, outputs)
```

Рис. 2. Программная реализация нейронной сети




Рис. 3. Схема построенной нейронной сети

Во время обучения модели в терминал выводится основная информация по ее состоянию, далее программа выводит архитектуру нейронной сети, затем проводит предсказание на тестовом наборе данных и выдает значения потерь. Значение точности модели 85,39 % показывает, что модель правильно классифицирует большинство тестовых данных. На графике точности (рис. 4, а) по оси X отложены эпохи обучения, по оси Y функция точности, синяя линия отвечает точности в рамках обучающей выборки, красная – в рамках валидационной. Точность предсказания при обучении растет первые 10 эпох, достигает уровня 0,95, на котором стабилизируется. Точность распознавания незнакомых данных также растет, однако медленнее, чем при обучении: результативность здесь достигает 87%. Соответствующее значение функции потерь составляет 0,4156, что представляется вполне приемлемым. На рисунке 4, б по оси Y отложена функция потерь, синяя линия отвечает потерям на обучающей выборке, а красная – на валидационной.




Рис. 4. Оценка нейронной сети: а) точность нейросети в процессе обучения; б) функция потерь в процессе обучения

В процессе обучения погрешность идентификации источника быстро сокращается, что свидетельствует успешному обучению. А на валидационной выборке потери также уменьшаются, но медленнее, чем на обучающей выборке, стабилизируясь около 0,35.

Представленные графики показывают, что разработанная нейронная сеть успешно учится на обучающих данных, достигая высокой точности и минимизируя потери.

В ходе выполнения данного исследования был проведен спектральный анализ звукового поля оборудования, реализован программный продукт классификации инструментов по записям их шума. Экспериментально установлено, что разработанная нейронная сеть быстро обучается и надежно квалифицирует источник производственного шума.

Список литературы

1. Atmaca E., Peker I., Altin A. Industrial Noise and Its Effects on Humans // Polish Journal of Environmental Studies. 2005, vol. 14, no. 6, pp. 721-726.
2. Wilson H. Artificial intelligence. – Grey House Publishing, 2018.

3. Jiang Y., Yin S., Li K., Luo H., Kaynak O. Industrial applications of digital twins // Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences. 2021, vol. 379, no. 2207, p. 20200360. DOI: 10.1098/rsta.2020.0360.

Сведения об авторах:

Бедюидзе Мария Васильевна – старший преподаватель кафедры «Прикладная математика», аспирант;

Богданец Диана Андреевна – студент;

Лесной Евгений Витальевич – студент;

Отрадных Кирилл Васильевич – магистрант;

Степаницын Артем Сергеевич – студент;

Харахашьян Артем Михайлович – к.т.н., доцент кафедры «Прикладная математика».