

## АКУСТИЧЕСКИЙ МОДЕМ: ОБНАРУЖЕНИЕ АНОМАЛИЙ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

Падневич Д.С., студент

Белорусский государственный университет информатики и радиоэлектроники  
г. Минск, Республика Беларусь

Лихачёв Д.С. – канд. техн. наук, доцент

В работе рассматривается реализация свёрточной нейронной сети для обнаружения аномалий и искажений в ЛЧМ-сигналах. Обоснован выбор гибридной архитектуры нейронной сети, основанной на двух моделях. Описан алгоритм моделирования помех в канале передачи. Разработка, обучение и оценка эффективности производились на языке Python с использованием библиотек PyTorch, NumPy и SciPy.

Традиционно, акустические модемы применяются в средах, где использование классических средств связи невозможно. Однако, из-за природы акустического канала, используемого для передачи данных, в нем могут возникать различные виды аномалий. Классические методы цифровой обработки сигналов, применяемые в акустических модемах, опираются на адаптивную фильтрацию и жёстко заданные математические модели канала. Данный подход требует высоких вычислительных мощностей и не всегда способен реагировать на сложные помехи, что приводит к снижению качества связи. Использование машинного обучения позволяет устройству самостоятельно выявлять сложные искажения в структуре сигнала, отличая допустимые шумы от критических дефектов. В ходе данной работы была разработана гибридная система обнаружения аномалий, решающая многие вышеописанные проблемы.

Для генерации обучающих и тестовых данных была разработана программная модель акустического канала связи. Базовый формирователь сигнала использует линейную частотную модуляцию. Логическому нулю соответствует символ с падающей частотой, а логической единице – с возрастающей. Основой симуляции реальной среды акустического канала стало добавление к сигналу гауссовского шума с заданным значением SNR, выраженным в децибелах. Также был разработан модуль вставки в модулированный сигнал локальных аномалий, применяющихся не ко всему кадру целиком, а к случайно выбранному сегменту, составляющему от 10% до 20% от общей длины сигнала.

В процессе проектирования, было выявлено, что использование только одной области анализа не позволяет с достаточной точностью обнаружить весь тестируемый список аномалий. Так, анализ двумерных спектрограмм отлично справлялся с выявлением частотных сдвигов и сильных зашумлений, однако, ввиду использования оконного преобразования Фурье, теряется фазовая информация. Анализ одномерного(сырого) сигнала же, напротив, хорошо выявляет клиппинг, эхо и фазовые искажения. Для компенсации этих недостатков, была разработана гибридная архитектура, состоящая из двух параллельно работающих свёрточных автоэнкодеров.

Модель двумерного автоэнкодера принимает на вход нормированные матрицы спектрограмм и предназначена для выявления частотных аномалий. Энкодер состоит из трёх последовательных свёрточных слоёв с ядром 3 на 3 и шагом 2. Количество фильтров постепенно увеличивается с 16 на первом слое до 32 на втором, а затем 64 на третьем. Декодер же использует слои транспонирующей свертки для восстановления исходного разрешения. Также используется функция ReLU, а на выходном слое – Sigmoid, что обеспечивает масштабирование восстановленных данных в диапазоне [0, 1]. На рисунке 1 представлены входные и выходные спектрограммы двумерной модели.




Рисунок 1 – Спектрограммы: а - исходная; б – восстановленная

Модель одномерного автоэнкодера ориентирована на работу с одномерными временными последовательностями. Архитектура энкодера построена на трех слоях одномерных свертки с ядром размером 7 и шагом 2. Аналогично двумерной модели, количество фильтров увеличивается постепенно с 16 до 64. Декодер функционирует аналогично вышеописанному, за исключением отсутствующей функции Sigmoid, убранной за ненадобностью. На рисунке 2 представлены сигналы на входе и выходе одномерной модели.




Рисунок 2 – График сигнала: а) - исходного; б) – восстановленного

Для обучения нейронных сетей был использован набор данных, состоящий из 10000 последовательностей, каждая из которых содержала 16 бит информации. В обучающую выборку был добавлен гауссовский шум с фиксированным значением SNR в 30 децибел. Сделано это было для того, чтобы обучить автоэнкодеры игнорировать фоновый шум, принимая его за нормальное состояние акустического канала.

Перед подачей данных на входы нейронных сетей, выполнялась их предварительная обработка. Для двумерного автоэнкодера, сигналы преобразовывались в спектрограммы с частотой дискретизации 44100 Гц и размером окна в 256 отсчётов. Полученные матрицы приводятся в диапазон  $[0, 1]$ , требуемому для корректной работы функции активации Sigmoid. Для одномерной модели, исходный сигнал разбивался на кадры в 256 отсчётов, сохраняющие во временной области исходную амплитуду.

Обучение проводилось в течении 50 эпох. В качестве оптимизатора использовался Adam, а минимизируемой функцией потерь являлась среднеквадратичная ошибка.

Для оценки эффективности обученных моделей, была использована тестовая выборка, содержащая сигналы с различными типами аномалий, не использованными в процессе обучения. Оценка проводилась по значению среднеквадратичной ошибки. При подаче на вход сигналов, не содержащих ошибок, модели успешно их восстанавливают. Однако при обнаружении аномалии, модель не может с точностью восстановить сигнал, вследствие чего показатель среднеквадратичной ошибки на участке резко повышался. Для расчёта порогового значения ошибки, была использована формула:

$$T = \mu + 4\sigma, \quad (1)$$

где  $T$  – порог СКО,  $\mu$  – среднее значение ошибки реконструкции,  $\sigma$  – среднее отклонение ошибки реконструкции.

На рисунке 3, представлены результаты работы детектора и сравнение ошибки реконструкции между двумя моделями. Исходные данные – ЛЧМ-сигнал с аномалией «кратковременное затухание».

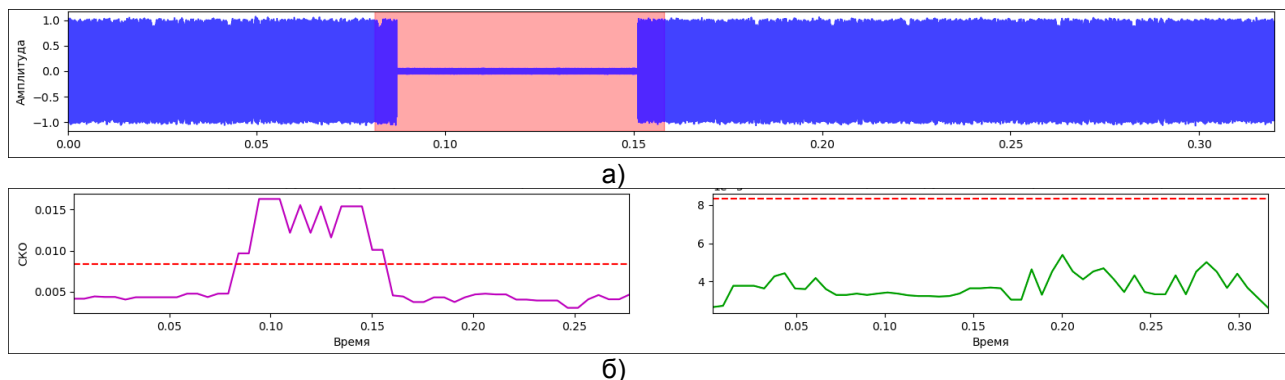


Рисунок 3 – Результат работы детектора: а) – обнаруженная аномалия; б) – сравнение ошибки реконструкции между моделями

Результаты тестирования и анализ графиков СКО подтверждают эффективность разработанной архитектуры. В отличие от одиночных моделей и других подобных решений, гибридный из двух автоэнкодеров обеспечивает более широкое покрытие спектра аномалий. Реализованный подход демонстрирует высокую адаптивность и позволяет выявлять сложные искажения акустического канала без необходимости их предварительного математического описания.

#### Список использованных источников:

1. Документация библиотеки PyTorch [Электронный ресурс]. – Режим доступа: <https://docs.pytorch.org/docs/stable/index.html>
2. Стивенс, Э. PyTorch. Освещающая глубокое обучение / Э. Стивенс, Л. Антика, Т. Виман. – СПб. : Питер, 2022. – 576 с.
3. Гудфеллоу, Я. Глубокое обучение : учеб. пособие / Я. Гудфеллоу, И. Бенджио, А. Курвилль. – М. : ДМК Пресс, 2017. – 652 с.