

УДК 004.032.26:621.391.82

## ПРИМЕНЕНИЕ ОДНОМЕРНЫХ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РАСПОЗНАВАНИЯ АНОМАЛИЙ БЕСПРОВОДНОГО КАНАЛА СВЯЗИ В УСЛОВИЯХ СИЛЬНЫХ РАДИОПОМЕХ

А.О. ПИЛИПЕНКО, С.А. ШВЕД,

*Белорусский государственный университет информатики и радиоэлектроники  
(г. Минск, Беларусь)*

*E-mail: stepan3310@gmail.com, pilipenkoandrej602@gmail.com,*

**Аннотация.** Классические методы защиты беспроводных каналов связи уязвимы перед динамическими изменениями радиоэлектронной обстановки. В данной работе представлена автоматизированная система на основе одномерной сверточной нейронной сети, спроектированная с нуля для мгновенного распознавания аномалий и блокирования умышленных радиопомех. За счет внедрения уникальной методики стресс-тестирования данных искусственным шумом разработанная модель достигает точности классификации 88,89% в условиях сильных искажений. Алгоритм служит готовым технологическим прототипом для интеграции в современные комплексы защиты беспроводных коммуникаций.

**Abstract.** Classic methods for protecting wireless communication channels are vulnerable to dynamic changes in the electronic environment. This paper presents an automated system based on a one-dimensional convolutional neural network, designed from the ground up to instantly recognize anomalies and block intentional radio interference. By implementing a unique data stress testing method with artificial noise, the developed model achieves 88.89% classification accuracy under severe distortion. The algorithm serves as a ready-made technological prototype for integration into modern wireless communications security systems.

### Введение

В современных реалиях быстрое распространение систем связи в смартфонах, компьютерах беспилотных аппаратах усиливаются риски безопасности. Упростила злоумышленникам проведение атак по блокированию сигналов в первую очередь доступность программно-определяемых радиосистем. Из-за постоянного усложнение радио фона эффективный ручной мониторинг невозможен, поэтому требуются внедрения автоматических решений. Основной задачей в настоящее время – оперативное обнаружение целенаправленного радиоглушения. Традиционные защитные комплексы работают по строго прописанным правилам, из-за чего совершают критические ошибки при появлении новых тактик атаки. Одномерные сверточные нейронные сети способны самостоятельно извлекать скрытые временные паттерны радиосигнала и, анализируя данные, динамически подстраиваться под новые типы помех [2, 3]. В данном проекте сеть обучается полностью самостоятельно, без использования сторонних пред обученных моделей.

### Входные данные и сквозной процесс вычислений

В качестве информационной основы исследования взят каталог файлов active\_scan. В нем есть три типа радиосигнала: фоновые сигналы, гауссовский шум и одно тональная помеха [1]. Фоновые сигналы представляют собой чистый эфир и естественную тишину, здесь нет никаких действий злоумышленника. Гауссовский шум – это широкополосная атака сплошным белым шумом. И последним типом радиосигнала в эфире является одно тональная помеха, представляющая собой узкополосный мощный удар по одной целевой частоте.

Далее хочется поговорить о порядке извлечения и математического преобразования признаков. Вначале происходит выделение информативных каналов. Из каждой текстовой таблицы исходных данных извлекаются 3 ключевых параметра: общий уровень хаоса в эфире, индикатор силы принимаемого сигнала и максимальная амплитуда пика. Далее формируются последовательности: данные преобразуются во временные блоки длиной по 128 отсчетов с тремя признаковыми каналами. Общий объем исследованной выборки составил 450 таких последовательностей. Затем вычисляется нормализация: для исключения ситуации, когда модель отдает ложный приоритет параметрам с большим числовым масштабом (например, силе сигнала со значением -90 по сравнению с шумом 0,001), проводится масштабирование в диапазон от -3 до 3. Вычисление выполняется путем вычитания из каждого текущего значения его среднего показателя по выборке с последующим делением результата на стандартное отклонение. В знаменатель при делении добавляется исчезающе малая константа для технического предотвращения ошибки деления на ноль. Далее метки векторизуются: целевые метки трех классов переводятся в векторный формат однократного кодирования. Выборка разделяется в пропорции 80% для обучения и 20% для проверки с фиксированным шагом случайного перемешивания под индексом 42.

На основе алгоритма обработки данных формируется последовательность прохождения информационных пакетов от источника к классификатору. Вначале наши исходные данные нарезаются на блоки по 128 отсчетов (сегментируются), потом значения масштабируются по среднему значению отклонения. Затем начинается аугментация – важный элемент последовательности подготовки данных, он представляет собой добавление на этапе обучения искусственного гауссовского шума с высоким уровнем 0,8 выступает в роли жесткого регулятора. Если сеть успешно выделяет маркеры радиоглушения на зашумленной лабораторной выборке, она гарантирует стабильную работу в непредсказуемых условиях реального эфира.

### **Архитектура модели**

Последовательная архитектура 1D-CNN была разработана специально для эффективной обработки временных рядов, она дает возможность полностью отказаться от использования сторонних пред обученных моделей. Система состоит из одномерных сверточных слоев, которые, используя скользящих фильтры, сканируют входной сигнал, чтобы найти специфические частоты и амплитудные паттерны. За ними следуют слои пулинга, выполняющие функцию сжатия данных и отсеивания не столь важной информации, это и позволяет нейросети сфокусироваться исключительно на самых значимых признаках. Чтобы не допустить переобучения, в структуру были внедрены слои Dropout, позволяющие путем случайного отключения нейронов заставляют модель выявлять глубокие закономерности вместо банального механического запоминания примеров. На следующем уровне работает слой Flatten («выравнивание»), который преобразует многомерные массивы данных в единый вектор, подготавливая их к финальному логическому анализу, где будет принято конкретное решение. Далее в работу включаются, выполняющие очень важную роль, полно связные слои, которые являются основным вычислительным центром. Они сопоставляя полученные признаки и принимают окончательное решение. Завершающим элементом цепи является выходной слой с функцией Softmax, который формирует итоговые вероятности принадлежности сигнала к одному из трех классов: фоновому фону, гауссовской или одно тональной помехе. Программная реализация слоев выполнена на базе спецификаций фреймворка TensorFlow/Keras [4].

### **Результаты эксперимента**

В ходе реализации проекта обучение нейросети проводилось в течение 20 эпох, за которые модель успешно прошла путь от распознавания явных признаков помех до анализа их скрытых закономерностей. Высокая эффективность обучения была обеспечена связкой оптимизатора Adam, который «подстраивал» внутренние параметры сети для минимизации ошибок, и функции кросс-энтропии, вычислявшей точность каждого прогноза. Графический анализ показал синхронное движение кривых обучения и валидации, что подтверждает стабильность алгоритма и полное отсутствие эффекта переобучения. Итоговым результатом стала точность распознавания в 88,89%, зафиксированная на специально усложненной зашумленной выборке. Полученный показатель является репрезентативным и надежным, так как отсутствие «лабораторных» 100% точности доказывает реальную готовность модели к работе в условиях непредсказуемого радиоэфира.

### **Заключение**

В заключении данной работы хочется отметить эффективность комплексного подхода: одновременный анализ параметров мощности, хаоса и пиковой амплитуды обеспечивает точную идентификацию аномалий радиоканала там, где стандартные жесткие правила бессильны. Отдельного внимания заслуживает устойчивость алгоритма, ведь самостоятельное обучение сети с нуля в сочетании со стрессовой аугментацией гарантирует корректную работу софта в реальном нестабильном эфире. Успешное тестирование проекта открывает перспективу масштабирования созданного математического ядра для интеграции непосредственно в программно-определяемые радиостанции, а также в аппаратные модули систем предотвращения и обнаружения сетевых вторжений.

### **Список использованных источников**

1. Ермолаев В. Т., Флакман А. Г., Сорокин А. А. Распознавание типов преднамеренных радиопомех методами глубокого обучения // Журнал радиоэлектроники. – 2022. – № 5. [Электронный ресурс]. URL: <http://jre.cplire.ru/jre/may22/3/text.pdf> (дата обращения: 21.05.2026).
2. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение. – М.: ДМК Пресс, 2018. – 652 с. (Перевод издания MIT Press, 2016).
3. Шолле Ф. Глубокое обучение на Python. – СПб.: Питер, 2022. – 400 с. (Перевод Книги Manning Publications, 2021).
4. TensorFlow / Keras Documentation: API Reference for Sequential model, Conv1D, Dropout, CategoricalCrossentropy. [Электронный ресурс]. URL: [https://www.tensorflow.org/api\\_docs](https://www.tensorflow.org/api_docs) (дата обращения: 18.05.2026).