

Определение внутриимпульсной модуляции радиосигнала с помощью искусственной нейронной сети при некогерентном приеме

И. С. Рудаков, Г.А. Милорадов, В.О. Скрипачев

Аннотация. В работе рассмотрены особенности применения нейросетевого подхода для решения задачи распознавания внутриимпульсной модуляции радиолокационных сигналов. Подчеркнута актуальность проблемы в контексте радиомониторинга и анализа радиоэлектронной обстановки. Описана методика построения признаков, используемых в классификации, включая этапы формирования обучающей выборки, добавления шума с различным уровнем отношения сигнал/шум (ОСШ), а также реализация алгоритма оценки точности модели. Продемонстрировано, что разработанный алгоритм позволяет эффективно классифицировать сигналы внутриимпульсной модуляции, такие как простой радиоимпульс, линейно-частотно модулированные сигналы прямого и обратного типа, а также, что предложенный алгоритм эффективно решает задачу классификации даже при значительном уровне шумов. Для проверки соответствующих подходов реализовано программное обеспечение на языке программирования Python. Отмечены особенности его работы. Полученные результаты подтверждают актуальность и применимость метода для задач радиомониторинга в условиях реальной радиоэлектронной обстановки.

Ключевые слова: компьютерное зрение, искусственные нейронные сети, радиолокационный сигнал, внутриимпульсная модуляция, распознавание модуляции, ЛЧМ (линейная частотная модуляция), смесь экспертов.

I. ВВЕДЕНИЕ

В современном мире интеллектуальные системы на основе искусственных нейронных сетей (ИНС) имеют большое распространение. Одной из ключевых задач, которые ИНС способны решить, это задачи радиомониторинга в контексте обеспечения корпоративной безопасности, например распознавание вида модуляции радиосигнала, что исследовано авторами исследований [1,2] применительно к связным сигналам с цифровой модуляцией. Так же задача определения параметров модуляции радиолокационных сигналов рассмотрена в работе [3,4]. Импульсные сигналы с ВИМ активно применяются в современных РЛС, в том числе в военных, авиационных и разведывательных системах. Способ модуляции несёт информацию о технических характеристиках передатчика, его назначении, а также позволяет

выполнять задачи идентификации и противодействия.

Задача осложняется высокой изменчивостью сигналов и требованиями к быстродействию при ограниченных вычислительных ресурсах. Несмотря на существование классических радиотехнических подходов, они зачастую оказываются слишком ресурсоёмкими для оперативного применения. В современных условиях особое значение приобретают методы обработки сигналов на основе интеллектуальных нейросетевых систем ИНС, которые позволяют эффективно классифицировать сложные виды модуляций. В данной работе реализован и исследован алгоритм на основе обычной и экспертной нейросетевой архитектуры (МоЕ), предназначенный для распознавания ВИМ радиолокационных сигналов с высокой точностью.

В ходе исследования рассматриваются следующие виды модуляций радиолокационных сигналов: прямоугольный радиоимпульс, линейно-частотная модуляция (ЛЧМ), обратная ЛЧМ, симметричная ЛЧМ, обратная симметричная ЛЧМ.

Программная реализация на Python обеспечивает возможность обучения и тестирования различных вариантов нейросетевых моделей, позволяя анализировать преимущества экспертного подхода (МоЕ) по сравнению с классическими ИНС в условиях реальных радиочастотных помех.

II. ИСПОЛЬЗУЕМЫЙ ПОДХОД ПРИ РАСПОЗНАВАНИИ ВНУТРИИМПУЛЬСНОЙ МОДУЛЯЦИИ РАДИОЛОКАЦИОННЫХ СИГНАЛОВ

Чтобы понять методику распознавания ВИМ РС (ЛЧМ, СЛЧМ, прямоугольный и др.) в условиях помех и динамических изменений, важно знать, что процесс распознавания вида модуляции делится на две подзадачи. Первая подзадача включает в себя обнаружение сигнала (детектирование факта его наличия). В рамках данного исследования задача обнаружения сигнала считается уже решенной, следовательно, в ходе работ учитываем, что сигнал точно существует в обрабатываемой реализации сигнала. И вторая подзадача, классификация типа модуляции

(идентификация вида ВИМ) – непосредственно решаемая задача.

Существует два наиболее распространённых подхода к распознаванию модуляции сигналов:

1. Метод максимизации функции правдоподобия (Maximum Likelihood, ML).

В основе этого подхода лежит статистическое сравнение отношения правдоподобия с заданным порогом. Недостатком данного метода является зависимость его эффективности от точности выбора порога и большое кол-во возможных гипотез при анализе реальных сигналов ввиду априорной неопределённости или неточности в оценки таких параметров сигналов как начальная фаза, частота, длительность и период импульса и т.д.

2. Признаковый подход (feature-based)

В данном случае формируется пространство признаков сигнала (например, статистические моменты, спектральные характеристики), после чего классификация типа модуляции выполняется с помощью алгоритмов машинного обучения (Machine Learning, ML). Например, на основании данных в работах [1,2,4] можно сделать вывод про применение нейронных сетей в задачах распознавания модуляций с практическими примерами такой реализации, с помощью нейронных сетей структуры CNN.

В данной работе рассмотрен второй подход в виду большой вероятности правильного распознавания, потенциально меньшего времени работы и меньших в сравнении с первым методом требований к вычислительным мощностям при анализе сигналов.

В настоящей работе используются алгоритмы машинного обучения, которые позволяют эффективно решать задачу определения ВИМ радиолокационного сигнала, учитывая различные сценарии, в том числе различное ОСШ, случайную выбранную начальную фазу.

Любая нейронная сеть состоит из нейронов, нейрон представляет собой простой нелинейный вычислительный элемент, идея искусственного нейрона пришла в машинное обучение из биологии [5,6].

Применимо к практическим задачам, обычно используется простейшая математическая модель такого нейрона.

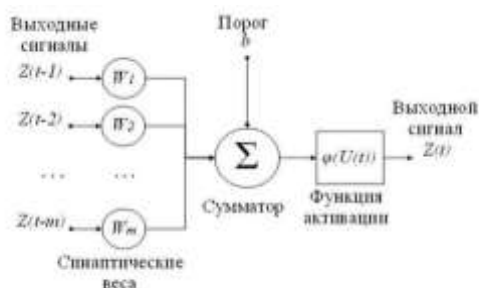


Рисунок 1 – Иллюстрация математической модели нейрона.

У такого нейрона также есть несколько входов, $Z(t-1)$, $Z(t-2) \dots (x_1 - x_n)$, уровень восприимчивости нейрона моделируется для улучшения модели в такой нейрон начали добавлять вес поляризации (в англ. литературе bias), тогда $net = \sum_{n=1}^N x_n w_n + b$, в некоторых реализациях вес поляризации не добавляется в явном виде, вместо него добавляют во входной вектор на нулевую позицию элемент равный единице, т.е. изначально входной вектор выглядел так, $X = \{x_1, x_2, x_3, \dots, x_N\}$, то после добавления нулевого входа вектор X выглядит так, $X = \{x_0, x_1, x_2, x_3, \dots, x_N\}$, где $x_0 = 1$, $net = \sum_{n=0}^N x_n w_n$. Затем используют активационные функции, В общем случае, математически выход одного нейрона можно представить таким образом [6].

$$Y = f_a(WX + B) \quad (1)$$

где Y — вектор выхода.

Для способности нейронной сети классифицировать несколько классов, многоклассовой классификации, их объединяют в слои. Базовый пример - полносвязные слои, такие слои, в которых все нейроны соединены со всеми входами. Для вычисления окончательного результата нейронной сети, требуется затем экстраполировать формулу (1).




Рисунок 2 – Визуализация слоёв нейронной сети.

Таким образом, происходит инициализация весов нейронной сети в каждом отдельном слое, но на этом процесс получения необходимого результата не завершен, теперь, необходимо обучить, то есть изменить веса нейронной сети таким образом, чтобы в результате классификация происходила максимально правильнейшим образом. Градиентные методы наиболее часто используются для обучения современных нейронных сетей, практически полностью вытеснив другие подходы. Наиболее распространены методы, основанные на первой производной, однако иногда применяются и методы, использующие вторую производную. Процесс обучения заключается в вычислении градиента функции ошибки от веса нейронные сети, данный градиент вычисляется по так называемому правилу цепи [5,6].

Правило цепи представляет собой дифференцирование сложной функции, такой метод, применённый к

нейронным сетям, называют методом обратного распространения ошибки (backpropagation).

Суть правила цепи заключается в следующем, изначально вычисляется производная от функции ошибки по выходам сети, далее это значение умножается на производную функция активации нейрона, после чего вычисляется производная по весовым коэффициентам, эти частные производные и является тем самым искомым градиентом функции ошибки по весовым коэффициентам.

В качестве функции ошибки используется половина квадрата отклонения выхода от идеального значения.

$$E = \frac{1}{2} \sum_{n=1}^N (y^n - t^n)^2 \quad (2)$$

где y выход нейрона на обучающем примере, t идеальный (ожидаемый) выход нейрона.

Проведённый анализ архитектуры нейронных сетей, их математической модели и методов обучения подтвердил целесообразность применения данного подхода к задаче распознавания внутриимпульсной модуляции радиолокационного сигнала. Рассмотрение градиентных методов, функций активации и структуры сети позволило обосновать выбор архитектуры и реализовать её с учётом таких факторов, как уровень шума и начальная фаза сигнала. Нейросетевой подход продемонстрировал высокую точность и устойчивость к искажениям в условиях, приближенных к условиям сложной радиоэлектронной обстановки.

Существует множество подходов к определению внутриимпульсной модуляции сигналов, включая методы, основанные на сверточных нейронных сетях (CNN) [5,6] а также более простые архитектуры, такие как многослойные перцептроны. В рамках данной реализации был выбран многослойный перцептрон с количеством нейронов, равным 256 в каждом слое. Такой выбор обусловлен необходимостью учета вычислительной сложности и скорости обработки сигналов, и является оптимальным для указанной задачи.

В отличие от CNN, требующих предварительной загрузки полного массива входных данных, нейросетевая структура обеспечивает возможность потоковой обработки, что важно с учетом требований к реальному времени.

Помимо прочего, для реализуемого подхода была предложена особая архитектура, которая может позволить улучшить точность модели, но как недостаток немного усложнить систему.

На представленной диаграмме ниже, Рисунок 3, изображена архитектура, реализующая подход Mixture of Experts (MoE), предназначенный для классификации сигналов с использованием нескольких специализированных нейронных сетей и мета-классификатора. Модель состоит из двух параллельных ветвей, каждая из которых обрабатывает входные данные, полученные различными способами.

Первая ветвь включает извлечение признаков, после чего они подаются на вход Нейронной сети эта сеть обучается на одном наборе данных и специализируется на определённом пространстве признаков.

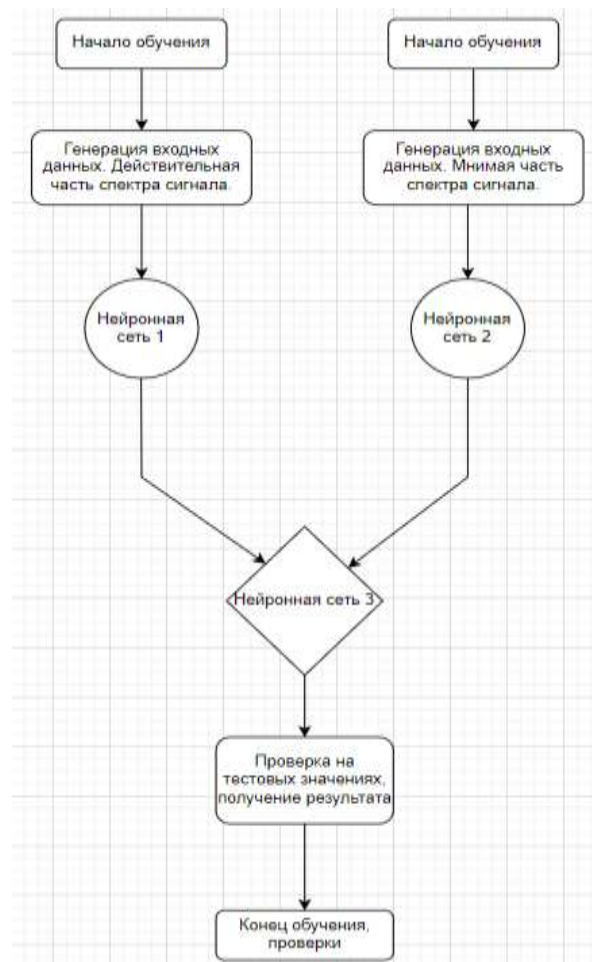


Рисунок 3 – Иллюстрация архитектурной структуры предложенного метода.

Вторая ветвь обучается на альтернативных данных, отличных от тех, на которых обучалась первая ветвь — что позволяет сформировать альтернативное представление входного сигнала, на основе которого обучается нейронная сеть. Таким образом, каждая нейронная сеть выполняет свою функцию в рамках определенного подпространства входных данных.

Результаты обеих сетей поступают на вход Нейронной сети 3, выполняющей роль управляющего элемента (gating network). Она обучается с учетом знаний о типе данных, на которых обучались НС1 и НС2, а также на основе анализа их откликов на конкретные входные сигналы. Мета-классификатор принимает решение о наиболее вероятной классификации, исходя из согласованности и надежности прогнозов обеих экспертных сетей.

Финальным этапом является выбор класса с максимальной апостериорной вероятностью. Такая архитектура позволяет повысить устойчивость модели к вариативности входных данных, обеспечивая

адаптивность и эффективность за счёт разделения обязанностей между экспертами и управляющей сетью.

В конкретной задаче, две разные нейронные сети будут обучены на разных частях амплитудного спектра, мнимой и действительной частях соответственно.

Такой подход позволяет иметь разные математические представления сигналов, для повышения качества определения модуляции в задаче распознавания вида модуляции.

На текущем этапе, была определена структура нейронной сети, и был изучен алгоритм обучения нейронной сети, но остался вопрос: какие данные использовать для нейронной сети для наилучшего распознавания ВИМ сигналов.

Одним из наиболее эффективных признаков в задаче идентификации вида модуляции сигнала является амплитудный спектр. Он позволяет выделить ключевые характеристики сигнала и обеспечивает устойчивость к различным искажениям, включая фазовые сдвиги. Ниже приведён сравнительный анализ альтернативных признаков, что позволяет обосновать выбор амплитудного спектра как основного.

Фазовый спектр представляет интерес с точки зрения анализа сигнальной структуры, однако его основным недостатком является высокая чувствительность к начальному фазовому сдвигу. При изменении начальной фазы амплитуда спектральных составляющих остаётся неизменной, тогда как фазовые характеристики могут значительно варьироваться. Это приводит к нестабильности признаков и усложняет задачу классификации.

Производная фазового спектра, или изменение фазы, теоретически может быть использована для анализа типа модуляции, однако на практике она требует значительных вычислительных ресурсов. Кроме того, данный признак нередко оказывается неточным в условиях наличия шума или нелинейных искажений, что снижает его надёжность в реальных задачах распознавания.

Автокорреляционная функция демонстрирует высокую точность при анализе сигнала и может эффективно использоваться для определения типа модуляции. Тем не менее, вычисление АКФ, особенно для сложных видов импульсной модуляции, сопровождается значительными затратами по ресурсам, что делает её менее предпочтительной, но возможно применимой вместо спектра сигнала.

Временное представление сигнала также может быть использовано для извлечения признаков, однако его информативность ограничена, особенно при работе с шумными или искажёнными данными. Визуальные характеристики в этом случае слабо отражают особенности конкретных типов модуляции.

На этом фоне амплитудный спектр выгодно выделяется по нескольким ключевым причинам. Во-

первых, он устойчив к начальному фазовому сдвигу, что повышает надёжность признаков. Во-вторых, наличие комплексной и реальной части позволяет более точно улавливать специфические особенности различных типов модуляции. В-третьих, обработка амплитудного спектра требует меньших вычислительных затрат по сравнению с АКФ или фазовой производной, что делает его более применимым в задачах с ограниченными ресурсами. Наконец, амплитудный спектр содержит достаточную информацию для точной классификации модуляционных схем, включая виды импульсной модуляции.

Целью дальнейших исследований может послужить использование других, альтернативных признаков, для обучения экспертной архитектуры нейронной сети.

III. РАЗРАБОТАННОЕ ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ ДЛЯ МОДЕЛИРОВАНИЯ

Для определения ВИМ сигналов разработана программа на языке Python. Использование Python позволяет использовать современные библиотеки для работы с нейронными сетями, такие как *tensorflow*, *keras*, и библиотеки отображения: *matplotlib.pyplot*, *seaborn*. Необходимое ПО предоставляет методы и функции для корректного исполнения заданной последовательности действий, а также для отображения результата вычислений.

В программе реализованы возможности регулирования настроек:

- генерация датасета с разным параметром сигнал шум;
- количество нейронов в каждом слое нейронной сети;
- количество слоев нейронной сети;
- регулировка эпох;
- регулировка отношения валидационной выборки к общей сгенерированной выборке;
- регулировка количества импульсов в периоде;
- регулировка скважности сигнала;

Также программа предоставляет возможность выполнения следующих базовых расчетов:

- нахождение результата, с помощью многослойной нейросетевой структуры;
- нахождение результата, с помощью усложненной экспертной архитектуры;
- возможность получить необходимые графики для разных SNR, и разных количеств слоёв (Рис. 5).

Программа имеет множество важных внутренних функций, обеспечивающих её работу. Кроме того, программа защищена от введения неправильных исходных данных.

В программе есть главная функция для обучения и теста нейронной сети `step()`. Она необходима для одного прохождения на заданных, выбранных пользователем параметрах. Данная функция создает необходимые данные, обучает нейронную сеть, и затем проверяет

корректность определения ВИМ и выдаёт пользователю результат в формате.

```

373/373          18 imgs/step
Confusion Matrix:
[[1715  136  201  217  142]
 [   24 1995  131  170  104]
 [   40  109 2154  28   29]
 [   37  143  18  2193  44]
 [   84  258  121  93 1814]]
end -3 Layer 3 Test Accuracy: 0.8225833177566528

```

Рисунок 4 – Иллюстрация вывода программы.

На приведённом выводе, можно увидеть матрицу рассеяния — табличное представление, отображающее количество верных и ошибочных классификаций, произведённых алгоритмом, по отношению к каждому классу. Также заданный коэффициент ОСШ количество слоёв нейронной сети, и аккуратность на тестовой выборке.

В качестве примера использования программы для узнаем значение распознавания ВИМ сигнала. С определёнными детерминированными параметрами. Параметры в квадратных скобках являются случайными. Например, [350;500] Гц – выбирается случайным образом от 350 до 500 Гц.

Начальная частота (НЧС) = [2.8e7; 3.0e7] Гц

Конечная частота (КЧС) = [3.0e7; 3.2e7] Гц

Частота дискретизации (ЧД) 1e4 Гц = 7e7 Гц

Длительность Импульса (Д) [1e-6; 1.1e-6] с

Сквозность 0.5.

Согласно теореме Котельникова любой сигнал, не содержащий частот выше некоторой граничной частоты F_{max} , может быть полностью восстановлен по его отсчётам, сделанным с частотой не ниже $2F_{max}$ [7].

$$f_s \geq 2F_{max} \quad (4)$$

Поэтому вышеуказанные параметры, связанные с частотами, являются оптимальными.

Для проведения эксперимента использовал датасет из 50000 сигналов, каждый тип модуляции был представлен 10000 сигналами. Результат распознавания ВИМ с помощью нейронной сети был получен с ОСШ 0 дБ, и с 4 слоями нейронной сети.

Вышеуказанный сценарий представляет собой наибольшее приближение к условиям реального радиолокационного канала. В данном случае все основные параметры сигнала, включая начальную и конечную частоты, длительность, а также начальную фазу, варьируются случайным образом в заданных диапазонах, что обеспечивает высокую степень вариативности и приближённость к реальной задаче классификации. В результате распознавания вида модуляции был получен результат 92,95% точности распознавания.

Распознавание дало высокий показатель точности поскольку нейросетевые методы способны искать скрытые закономерности, что позволяет отличить различные ВИМ радиолокационных сигналов.

Сравнительный анализ эффективности в шестом сценарии (радиолокационные сигналы высокой частоты) показывает, что экспертная модель (94,5%) сохраняет преимущество перед нейросетевой архитектурой (92,95%), хотя разница сокращается до 1,55%. Предложенная модель, как выяснилось, обеспечивает более высокий результат. Наблюдаемое незначительное превосходство экспертной системы объясняется альтернативным видом сигнала, на основании которого можно получить новые знания.

Для более наглядного представления результатов, для некоторых испытаний, был проведён анализ точности классификации сигналов при изменении ОСШ в диапазоне от -5 дБ до 10 дБ. Для каждого уровня ОСШ создавался новый датасет из 50 000 сигналов (по 10 000 каждого типа). После обработки данных модель обучалась и тестировалась, а результаты классификации наносились на график. Таким образом можно наглядно увидеть результат определения при различных фиксированных уровнях шума.

На рисунках 5 и 6 рассматриваются различные результаты точности распознавания видов модуляции (ось y) в зависимости от отношения сигнал шум (ось x). Разными цветами показаны результаты для разных количеств слоёв нейросетевых структур.

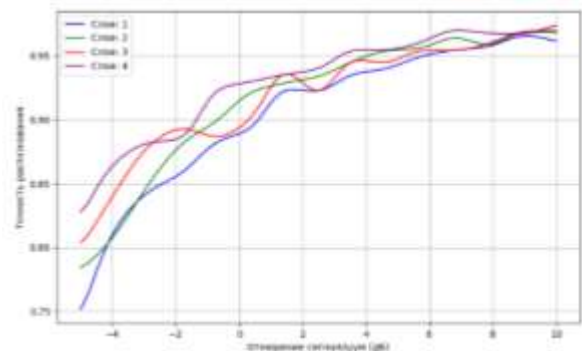


Рисунок 5 – Результат точности определения ВИМ полносвязная нейронная сеть.




Рисунок 6 – Результат точности определения ВИМ с экспертная модель нейронной сети.

При низком ОСШ (менее 2 дБ) модель показывает снижение точности распознавания видов модуляции, поскольку шумовые искажения делают спектральные характеристики различных модуляций

более схожими. Такое поведение также указывает на ограниченную способность модели работать при низком ОСШ. При увеличении количества слоёв, данные имеют более правильный тренд возрастания, лучшими оказались результаты, имеющие 4 слоя в составе нейросетевых архитектур.

Далее, описано проведение экспериментов, в которых данные генерировались не с определённым, заранее фиксированным уровнем ОСШ от -5 дБ до 10 дБ, а с шагом 1дБ. То есть на каждый шаг -5 дБ, -4 дБ ... генерировалось 5000 сигналов (или 10000) каждого вида, затем созданный датасет разбивался на выборки с разным ОСШ, и таким образом получался результат, характеризующий точность определения.

Классическая нейросетевая полносвязная архитектура, обученная на аналогичном объёме данных с учётом каждого уровня шума, показала точность 94,8%, а при обучении на датасете в 10000 сигналов каждого вида, 95,08% точности распознавания. Для сравнения, экспертная модель показала результат 93,68% при 5000 сигналов, и 96,38% при 10000 сигналов соответственно. Эти результаты демонстрируют, что увеличение объема обучающей выборки и учёт структурных особенностей модели позволяют существенно повысить эффективность распознавания в условиях приближённых к реальным.

Таким образом, нейросетевые модели продемонстрировали устойчивость к изменению уровня шума и успешно справились с задачей определения вида внутриимпульсной модуляции, без возникновения каких-либо проблем, характерных для радиотехнических методов. Помимо прочего, был проведён сравнительный анализ предложенных архитектур.

IV. ЗАКЛЮЧЕНИЕ

Таким образом, применение нейронных сетей в задаче распознавания внутриимпульсной модуляции радиолокационных сигналов оказалось крайне эффективным, и помимо прочего является оптимальным выбором в соотношении качества распознавания/вычислительные ресурсы. Разработанная программа позволяет моделировать разные случаи взаимодействия с внутриимпульсными модуляциями, является крайне гибкой и настраиваемой.

В ходе статьи произведен анализ использования разных архитектурных моделей нейронных сетей, при различных параметрах. Результаты моделирования могут быть использованы для задач радиомониторинга, радиолюбителями, а также разработки стратегий, специфичных для данной узконаправленной области.

БИБЛИОГРАФИЯ

[1] Аджемов, С. С. Нейросетевой метод распознавания видов модуляции радиосигналов с использованием кумулянтов высокого порядка / С. С. Аджемов, М. В. Терешонок, Д. С. Чиров // Т-Comm: Телекоммуникации и транспорт. – 2012. – Т. 6, № 9. – С. 9-12. – EDN MRSQUM.

- [2] Парамонов, А. А. Распознавание видов цифровой модуляции радиосигналов с использованием многозадачной нейронной сети / А. А. Парамонов, М. В. Нгуен // Вестник воздушно-космической обороны. – 2022. – № 4(36). – С. 91-97. – EDN CQBGHY.
- [3] Чиров, Д. С. Анализ методов распознавания видов межимпульсной модуляции сигналов радиолокационных средств / Д. С. Чиров, Е. О. Кандаурова // Т-Comm: Телекоммуникации и транспорт. – 2019. – Т. 13, № 3. – С. 15-23. – DOI 10.2441/1/2072-8735-2018-10243. – EDN WVRGXF.
- [4] Qu, Z.; Mao, X.; Deng, Z. Radar Signal Intra-Pulse Modulation Recognition Based on Convolutional Neural Network. *IEEE Access* 2018, 6, 43874–43884.
- [5] Мухамедиев Р.И., Амиргалиев Е.Н. Введение в машинное обучение: Учебник. – Алматы, 2023. – 471 с.
- [6] Нейронные сети : полный курс / Саймон Хайкин ; [пер. с англ. Н. Н. Куусуль, А. Ю. Шелестова]. - Изд. 2-е, испр. - Москва [и др.] : Вильямс, 2008. - 1103 с.
- [7] Оппенгейм, А. В. Цифровая обработка сигналов / А. В. Оппенгейм, Р. В. Шафер. – Издание 3-е, исправленное. – Москва : Рекламно-издательский центр "Техносфера", 2012. – 1048 с. – (Мир радиоэлектроники). – ISBN 978-5-94836-329-5. – EDN HEGVVO.

Статья получена 24 апреля 2025.

И.С. Рудаков, студент института радиоэлектроники и информатики ФГБОУ ВО «МИРЭА – Российский технологический университет», Москва, Россия (e-mail: vano13378@mail.ru)

Г.А. Милорадов, ассистент кафедры радиоэлектронных систем и комплексов института радиоэлектроники и информатики ФГБОУ ВО «МИРЭА – Российский технологический университет», Москва, Россия (e-mail: miloradov@mail.ru)

Скрипачев В.О., к.т.н., доцент кафедры радиоэлектронных систем и комплексов института радиоэлектроники и информатики ФГБОУ ВО «МИРЭА – Российский технологический университет», Москва, Россия (e-mail: skripatchevv@inbox.ru)

Modeling of recoverable radioelectronic systems with redundancy

Ivan Rudakov, Gleb Miloradov, Vladimir Skripachev

Abstract. This paper explores the features of applying a neural network approach to solve the problem of recognizing intra-pulse modulation of radar signals. The relevance of the problem is highlighted in the context of radio monitoring and analysis of the electronic environment. The methodology for building the features used in classification is described, including the stages of forming a training dataset, adding noise with different signal-to-noise ratio (SNR) levels, and implementing an algorithm for assessing model accuracy. It is demonstrated that the developed algorithm effectively classifies intra-pulse modulation signals, such as simple radio pulses, linear frequency-modulated signals (up-chirp and down-chirp), and that the proposed algorithm effectively solves the classification problem even under significant noise levels. To test the relevant approaches, software was implemented in the Python programming language. Its operational features are noted. The obtained results confirm the relevance and applicability of the method for radio monitoring tasks in real-world electronic environment conditions.

Keywords: computer vision, artificial neural networks, radar signal, intra-pulse modulation, modulation recognition, LFM (Linear Frequency Modulation), expert mixtures.

REFERENCES

- [1] Adzhemov, S. S. Neyrosetevoy metod raspoznavaniya vidov modulyatsii radiosignalov s ispol'zovaniem kumulyantov vysokogo poryadka / S. S. Adzhemov, M. V. Tereshonok, D. S. Chirov // T-Comm: Telekommunikatsii i transport. – 2012. – T. 6, № 9. – S. 9-12. – EDN MRSQUM.
- [2] Paramonov, A. A. Raspoznavanie vidov tsifrovoy modulyatsii radiosignalov s ispol'zovaniem mnogozadachnoy neyronnoy seti / A. A. Paramonov, M. V. Nguen // Vestnik vozdushno-kosmicheskoy oborony. – 2022. – № 4(36). – S. 91-97. – EDNCQBGHY.
- [3] Chirov, D. S. Analiz metodov raspoznavaniya vidov mezhimpulsnoy modulyatsii signalov radiolokatsionnykh sredstv / D. S. Chirov, E. O. Kandaurova // T-Comm: Telekommunikatsii i transport. – 2019. – T. 13, № 3. – S. 15-23. – DOI 10.24411/2072-8735-2018-10243. – EDN WVRGXF.
- [4] Qu, Z.; Mao, X.; Deng, Z. Radar Signal Intra-Pulse Modulation Recognition Based on Convolutional Neural Network. IEEE Access 2018, 6, 43874–43884
- [5] Mukhamediev R.I., Amirgaliev E.N. Vvedenie v mashinnoe obuchenie: Uchebnyk. – Almaty, 2023. – 471 s.
- [6] Neyronnye seti : polnyy kurs / Saymon Khaykin ; [per. s angl. N. N. Kussul', A. Yu. Shelestova]. - Izd. 2-e, ispr. - Moskva [i dr.] : Vilyams, 2008. - 1103 s.
- [7] Oppengeym, A. V. Tsifrovaya obrabotka signalov / A. V. Oppengeym, R. V. Shafer. – Izdanie 3-e, ispravlennoe. – Moskva : Reklamno-izdatel'skiy tsentr "Tekhnosfera", 2012. – 1048 s. – (Mir radioelektroniki). – ISBN 978-5-94836-329-5. – EDN HEGVVO.