

**Суминов Константин Александрович** – ПАО «ИНЭУМ им. И.С. Брука»; e-mail: Konstantin.A.Suminov@mcst.ru; г. Москва, Россия; тел.: +74991355336; начальник отдела.

**Бочаров Никита Алексеевич** – ПАО «ИНЭУМ им. И.С. Брука»; e-mail: bocharov.na@phystech.edu; г. Москва, Россия; тел.: +79167346437; к.т.н.; зам. руководителя управления; г.н.с.

**Кирилюк Михаил Андреевич** – ПАО «ИНЭУМ им. И.С. Брука»; e-mail: kirilyuk\_m@ineum.ru; г. Москва, Россия; тел.: +79055273011; к.т.н.; начальник отдела; с.н.с.

**Suminov Konstantin Alexandrovich** – JSC «INEUM»; e-mail: Konstantin.A.Suminov@mcst.ru; Moscow, Russia; phone: +74991355336; head of department.

**Bocharov Nikita Alexeevich** – JSC «INEUM»; e-mail: bocharov.na@phystech.edu; Moscow, Russia; phone: +79167346437; cand. of eng. sc.; deputy head of division; chief researcher.

**Kirilyuk Mikhail Andreevich** – JSC «INEUM»; e-mail: Mikhail.A.Kirilyuk@mcst.ru; Moscow, Russia; phone: +79055273011; cand. of eng. sc.; head of department, senior researcher.

УДК 621.391:004.032.26

DOI 10.18522/2311-3103-2025-2-289-298

**Д.В. Шумков, И.В. Титков, П.А. Гулевич**

### **ПРИМЕНЕНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ТЕХНИЧЕСКОГО РАСПОЗНАВАНИЯ ОБЪЕКТОВ В ИНТЕРЕСАХ РАДИОМОНИТОРИНГА**

*Рассматривается исследование возможности применения свёрточных нейронных сетей (СНС) для технического распознавания объектов (ТРО) в контексте радиомониторинга. Основное внимание уделяется разработке и оптимизации алгоритмов обработки радиолокационных сигналов с использованием глубоких нейронных сетей. Исследования показали, что применение СНС позволяет существенно повысить точность классификации радиосигналов по сравнению с традиционными методами обработки. Разработанный подход основан на извлечении иерархических признаков из спектральных изображений радиосигналов и их последующей классификации с помощью обученной нейронной сети. В работе представлены результаты экспериментальных исследований, проведённых на наборе данных, включающем более 10 000 образцов радиосигналов различных типов. Показано, что предложенная методика обеспечивает точность распознавания до 93% при работе с зашумлёнными сигналами и вероятность ложной тревоги не более 0,05. Особое внимание уделено вопросам выбора архитектуры нейронной сети под специфику задачи радиомониторинга. Также было детально рассмотрены варианты преобразования в спектральное изображение радиосигналов, для обработки в режиме реального времени. Разработаны методы предварительной обработки данных, включающие нормализацию амплитуды, частотную коррекцию и устранение помех. Результаты исследования могут найти применение в системах контроля радиоэфира и обеспечения электромагнитной совместимости радиоэлектронных средств. Полученные результаты демонстрируют перспективность использования СНС в задачах технического распознавания объектов радиомониторинга и открывают новые возможности для развития методов интеллектуальной обработки радиолокационной информации. Перспективные направления дальнейших исследований включают разработку адаптивных методов обучения нейронных сетей в условиях изменяющейся радиообстановки и создание гибридных систем, сочетающих традиционные методы обработки сигналов с современными нейросетевыми алгоритмами.*

*Радиомониторинг; свёрточные нейронные сети; классификация объектов в радиоэфире; метод; алгоритм; эксперимент.*

**D.V. Shumkov, I.V. Titkov, P.A. Gulevich**

### **APPLICATION OF CONVOLUTIONAL NEURAL NETWORKS FOR TECHNICAL OBJECT RECOGNITION IN THE INTERESTS OF RADIO MONITORING**

*The article examines the possibility of using convolutional neural networks for technical object recognition in the context of radio monitoring. The focus is on the development and optimization of algorithms for processing radar signals using deep neural networks. Studies have shown that the use of CNN can significantly improve the classification accuracy of radio signals compared to traditional processing*

methods. The developed approach is based on the extraction of hierarchical features from spectral images of radio signals and their subsequent classification using a trained neural network. The paper presents the results of experimental studies conducted on a dataset of more than 10,000 samples of radio signals of various types. It is shown that the proposed technique ensures recognition accuracy of up to 94% when working with noisy signals and the probability of a false alarm is no more than 0.05. Special attention is paid to the choice of neural network architecture for the specifics of the radio monitoring task. The options for converting radio signals into a spectral image for real-time processing were also considered in detail. Data preprocessing methods have been developed, including amplitude normalization, frequency correction, and interference elimination. The results of the study can be used in radio broadcast control systems and to ensure electromagnetic compatibility of electronic devices. The results obtained demonstrate the prospects of using CNN in the tasks of technical recognition of radio monitoring objects and open new opportunities for the development of intelligent radar information processing methods. Promising areas of further research include the development of adaptive neural network training methods in a changing radio environment and the creation of hybrid systems combining traditional signal processing methods with modern neural network algorithms.

Radio monitoring; convolutional neural networks; classification of objects in radio; method; algorithm; experiment.

**Введение.** В современных условиях стремительного развития радиоэлектронных технологий и увеличения плотности радиозэфира особую актуальность приобретает задача эффективного технического распознавания объектов при радиомониторинге. Традиционные методы обработки радиосигналов, основанные на анализе отдельных параметров, демонстрируют ограниченную эффективность при работе со сложными сигналами в условиях помех и динамически изменяющейся обстановки [1–5].

В последние годы наблюдается растущий интерес к применению методов глубокого обучения для решения задач радиомониторинга. Особую перспективу демонстрируют СНС, показавшие высокую эффективность в задачах обработки изображений и временных рядов [6]. При этом специфика работы с радиосигналами требует разработки специализированных архитектур и методик обучения СНС, учитывающих особенности радиозэфира.

Целью данной работы является исследование возможностей применения сверточных нейронных сетей для технического распознавания объектов при радиомониторинге.

**Основная часть.** Для рассматриваемой задачи было принято решение разработать способ ТРО радиомониторинга с использованием нейронных сетей. При разработке способа были вынесены за рамки исследования следующие вопросы: особенности и правила добавления примеров из существующей обучающей выборки для обучения нейронной сети, особенности и критерии принятия решения о количестве замороженных слоев при обучении сверточной нейронной сети методом «переноса обучения» (*Transfer Learning*) [7].

По результатам [8] выбора методов, входящих в составные части способа ТРО радиомониторинга с использованием нейронных сетей, далее будет описываться каналы и правила приема информации о появлении новых объектов радиомониторинга от внешних источников информации [9].

Входными данными для применения способа являются:

а) в режиме классификации:

◆ принятый радиозэфир ( $f_{\text{нижняя}}$  – нижняя частота спектра;  $f_{\text{верхняя}}$  – верхняя частота спектра,  $f_{\text{диап.}}$  – частотный диапазон,  $t_{\text{радиозэфира}}$  – время принятого радиозэфира,  $P_{\text{радиозэфира}}$  – мощность сигнала принятого радиозэфира);

б) в режиме накопления выборки и обучения нейронной сети:

◆ принятый радиозэфир ( $f_{\text{нижняя}}$  – нижняя частота спектра;  $f_{\text{верхняя}}$  – верхняя частота спектра,  $f_{\text{диап.}}$  – частотный диапазон,  $t_{\text{радиозэфира}}$  – время принятого радиозэфира,  $P_{\text{радиозэфира}}$  – мощность сигнала принятого радиозэфира);

◆ перечень объектов классификации с привязкой по времени подтвержденного нахождения в зоне записи радиозэфира ( $P_{\text{объект}}$  наименование объекта, работающая РЛС, режим работы РЛС в формате объект, тип РЛС, режим работы РЛС,  $t_{\text{нач.фикс.}}$   $t_{\text{кон.фикс.}}$  время нахождения в зоне записи радиозэфира с ... по в формате дата : час : минуты : секунды).

По результатам применения способа получаем следующие данные:

а) в режиме классификации:

- ♦ распознанный объект радиомониторинга ( $P_{\text{объект}}$  наименование объекта, работающая РЛС, режим работы РЛС в формате объект: тип РЛС : режим работы РЛС: вероятность классификации).

б) в режиме накопления выборки и обучения нейронной сети:

- ♦ весовые коэффициенты сверточной нейронной сети (представляет собой массив чисел, отражающий весовые коэффициенты межнейронных связей в формате [вес нейронной связи 1–1 слоя 1–2, вес нейронной связи 1–2 слоя 1–2 слоя, ... вес нейронной связи  $n$ - $f$  слоя  $r$ -1- $r$  слоя] к примеру [25292.383561, 136272.32865, ... , -5568.383561]);

- ♦ библиотека классов распознавания ( $P_{\text{инс}}$  класс СНС –  $P_{\text{объект}}$ ).

Процесс ТРО радиомониторинга с помощью нейронных сетей в соответствии с разработанным способом проходит по следующему алгоритму (рис. 1-3) [13]:

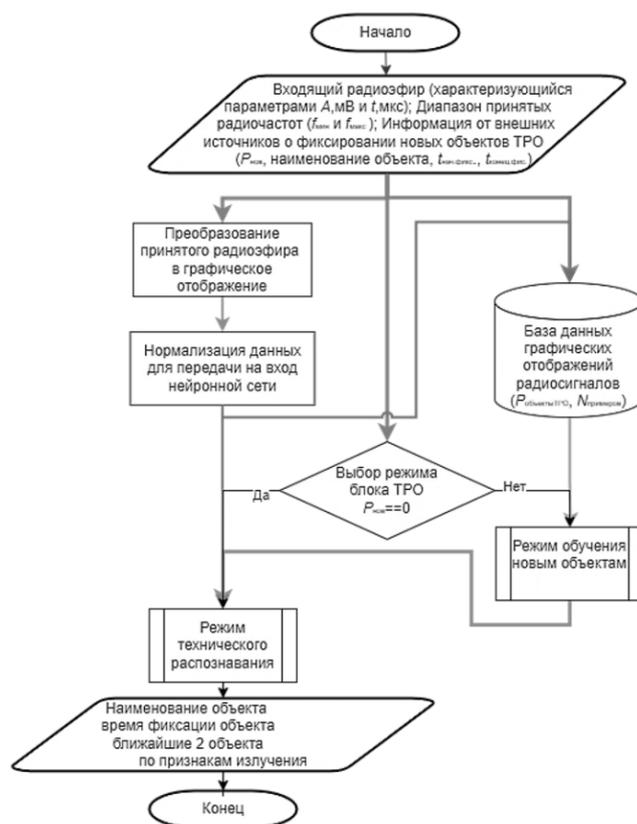


Рис. 1. Алгоритм работы технического распознавания объектов радиомониторинга с помощью нейронных сетей [13]

Входная информация: сигнал радиоэфира, принятый антенной, характеризующийся следующими параметрами  $A$  – амплитуда принятого сигнала во времени  $t$ , дБ,  $t$  – время и описываемый формулой 1 [10]:

$$S(t) = A \times e^{-i\omega_0 t}. \quad (1)$$

После приема сигнал преобразовывается с помощью оконного преобразования Фурье для разложения на частотный спектр по формуле (2) [11]:

$$STFT(\omega, t) = \frac{1}{\beta} \int_{-\infty}^{\infty} w(t - \tau)x(t)e^{-i\omega\tau} dt. \quad (2)$$

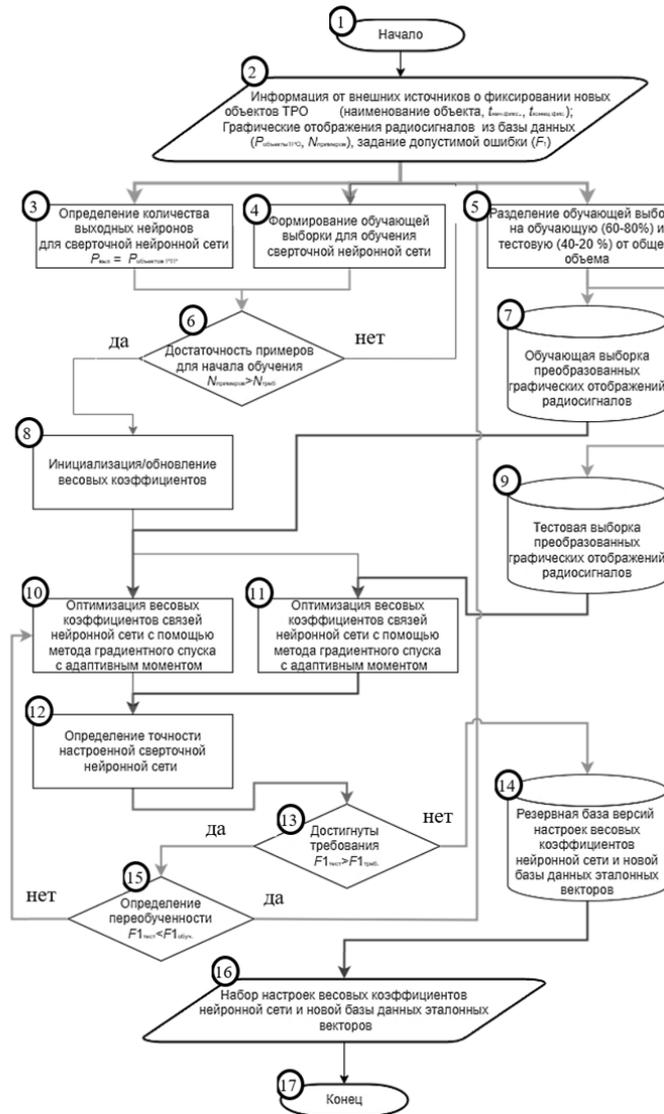


Рис. 2. Алгоритм ТРО радиомониторинга с нейронной сетью. Блок обучения новым объектам [13]

Выходными параметрами на этом этапе являются  $A(f, t)$  – амплитуда сигнала на частоте  $f$  в момент времени  $t$ ,  $f$  – частотный спектр,  $t$  – момент времени.

Далее определяется интересующий частотный диапазон для поиска источников излучения  $f_{треб} = (f_{мин.треб.} : f_{макс.треб.})$ . Для преобразования сигнала в графический портрет, подаваемый на вход нейронной сети необходимо провести нормализацию по формуле (3) [14]:

$$z' = \frac{z - z_{min}}{z_{max} - z_{min}} (u - l) + l, \tag{3}$$

где  $z$  – исходные данные,  $z'$  – нормализованные данные,  $z_{max}$ ,  $z_{min}$  – максимальное и минимальное значение нормализуемых данных,  $u$ ,  $l$  – верхнее и нижнее значение нового диапазона для нормализации данных,  $z' \in [l; u]$ .

После проведения нормализации преобразованный радиоэфир нарезается в графические отображения квадратной формы, где ширина и длина графического отображения будут соответствовать друг другу, это является необходимым условием для ускорения обработки сверточной нейронной сетью радиоэфира.

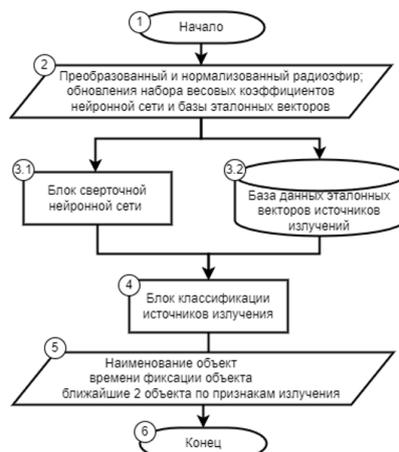


Рис. 3. Алгоритм ТРО радиомониторинга с нейронной сетью.  
Блок технического распознавания [13]

Далее принимается решение о работе способа в режиме обучения, либо в режиме классификации по правилу (4) [13]:

$$P_{\text{нов}} == 0, \quad (4)$$

где  $P_{\text{нов}}$  – количество новых объектов радиомониторинга, полученных в ходе приема радиоэфира.

При невыполнении условия, указанного в формуле (4), способ начинает работать в режиме обучения нейронной сети новым объектам радиомониторинга.

Для достижения данной задачи выделяется часть входящего радиоэфира, на котором было предположительно записано излучение нового объекта радиомониторинга.

*Этап 1.* Определяется количество выходных нейронов для новой нейронной сети исходя из количества объектов распознавания  $P_{\text{вых.}} = P_{\text{объектов.ТРО}}$ .

*Этап 2.* Принятие решения для первичного обучения нейронной сети либо для дообучения существующей нейронной сети новым объектам радиомониторинга.

*Этап 3.* Принятие решения о достаточности примеров для обучения или дообучения нейронной сети по правилу (5) [15]:

$$N_{\text{примеров}} \geq N_{\text{треб.}}, \quad (5)$$

где  $N_{\text{примеров}}$  – количество примеров полученных для обучения СНС,

$N_{\text{треб.}}$  – количество примеров требуемых для обучения СНС.

*Этап 4.* Инициализация/обновление весовых коэффициентов обучаемой нейронной сети. Задание максимально допустимой ошибки на обучение. Указание дискретного шага обучения нейронной сети [15].

*Этап 5.* Оптимизация весовых коэффициентов нейронной сети с помощью метода адаптивного момента градиентного спуска, двух СНС на базе обучающей и тестовых выборок.

*Этап 6.* Сравнение полученных точностей, полученных на тестовой и обучающей выборках. Принятие решения об остановке обучения СНС при достижении состояния переобученности. Данное состояние характеризуется снижением показателя точности нейронной сети на тестовой выборке, более чем в двух эпохах обучения. Обучение останавливается, и наилучшая конфигурация нейронной сети, полученная в ходе обучения с показателями точности классификации, сравнивается с требуемыми показателями, выставленными заранее (6) [16]:

$$F_{1\text{тест}} \geq F_{1\text{треб.}} \quad (6)$$

При недостижении требований  $F_{1\text{треб}}$  способ переходит к исполнению этапа 4, в случае повторного перехода на этап 4 принимается решение о переходе к этапу 3 и увеличению показателя  $N_{\text{треб}}$  на 15%, после чего проводится повторение всех последующих пунктов.

При достижении требований  $F_{\text{треб}}$  параметры нейронной сети (весовые коэффициенты и количество выходных нейронов (соответствующих новому количеству объектов радиомониторинга) передаются для работы в режиме классификации.

При выполнении условия, указанного в формуле (6), способ начинает работать в режиме ТРО.

*Этап 1.* Каждый из отрезков поступающего радиоэфира последовательно подается на вход обученной сверточной нейронной.

*Этап 2.* Происходит сложение всех весовых коэффициентов в нейронной сети, перемноженных на входные параметры (графического отображения радиоэфира). Результатом выполнения второго этапа является вероятностные данные о нахождении в радиоэфире того или иного источника излучения, в том числе об отсутствии каких-либо излучений. Выходом нейронной сети является вектор вида (7):

$$y = [y_1, y_2, y_3, \dots, y_N], \quad (7)$$

где  $N$  – количество классифицируемых классов +1 класс [17].

К примеру:  $y = [0.19, 0.24, 0.44, 0.04, 0.78, 0, 0, 0]$ , что означает что в анализируемом эфире с вероятностью в 19% есть излучатель класса 1, с вероятностью 24% излучатель класса 2, с вероятностью 44% излучатель класса 3, с вероятностью 4% излучатель класса 4, с вероятностью 78% излучатель класса 5, принадлежность излучения к классам 6, 7 и 8 равно 0%.

*Этап 3.* Сопоставление полученного вектора с базой данных классов [18, 19], в которых описаны детальные характеристики, такие как излучатель сигнала, режим работы излучателя, объект управления, что и является конечной целью применения данного способа в интересах радиомониторинга. Итогом работы способа является информация следующего вида: с 15:57 по 16:10 14.10.2023 г. выявлена работа комплекса управления *GCS-303*, объект управления комплекса беспилотный дрон модели *JOUAV CW-40 Gasoline*, опознавательный номер JCW 4006 с вероятностью 78%.

Также можно указывать до 5 следующих выявленных объектов, тогда выдаваемая информация будет иметь вид (табл. 1):

Таблица 1

**Выдаваемая информация по результатам применения способа [13]**

Комплекс излучения	Объект управления	Бортовой номер	Вероятность, %
<i>GCS-303</i>	JOUAV CW-40 Gasoline	JCW 4006	78
<i>GCS-303</i>	JOUAV CW-40 Gasoline	JCW 4001	44
<i>GCS-303</i>	JOUAV CW-30E	JCW 3012	24
<i>GCS-303</i>	JOUAV CW-25H	JCW 2590	19
<i>GCS-303</i>	JOUAV CW-25H	JCW 2521	4

По результатам разработки способа можно построить концептуальную модель функционирования блока ТРО в комплексе радиомониторинга (рис. 4) [12].

Для подтверждения гипотезы о возможности применения разработанного способа было проведено компьютерное моделирование. Для проведения моделирования была выбрана база данных Национального института стандартизации и технологии США. Выбранная база данных включает в себя наборы записей радиолокационных станций одной и той же модели, но разных партий изготовления. Выбранные данные наилучшим образом подходят для проведения экспериментального исследования, так как в полной мере отражает проблему технического распознавания разных источников излучения с одинаковыми параметрами [18].

База данных состоит из 20000 размеченных записей сигналов, среди которых присутствуют 6 работающих радиолокационных станций на частоте 3,5 ГГц.

Моделирование происходило на языке программирования *Python* версии 3.10.4, в среде разработки *PyCharm* версии 2023.2.1. Библиотеки, используемые при проведении эксперимента: *numpy*, *tqdm*, *h5py*, *pathlib*, *pandas*, *matplotlib*, *cv2*, *librosa*, *seaborn*. Моделирование происходило на базе операционной системы *Windows 10 Pro*, сборка операционной системы 19045.2604, характеристики АРМ центральный процессор *Intel Core i7-*

4771 3.50 ГГц, оперативная память 16 Гб частота работы памяти 2400 МГц, видеокарта *NVIDIA GeForce GTX 750* видеопамять 2 Гб, частота работы памяти 5000 ГГц частота работы процессора видеокарты 1020 МГц.

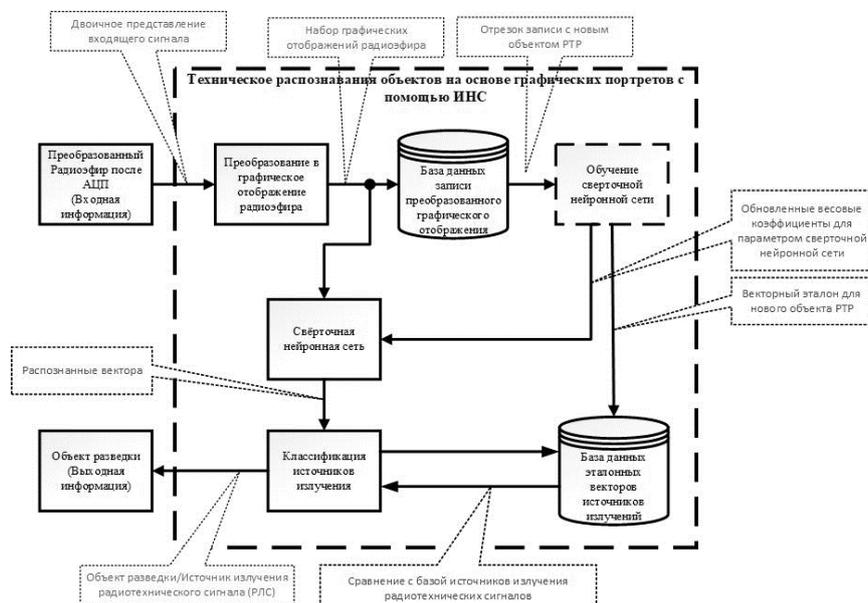


Рис. 4. Концептуальная модель ТРО на основе применения сверточной нейронной сети [13]

Ввиду отсутствия необходимых вычислительных мощностей для обучения нейронной сети был использован метод «переноса обучения» *Transfer Learning* [19], который предполагает перенос части весовых коэффициентов нейронной сети «донора» и дообучение меньшего количества слоев нейронной сети под новые классы распознавания. Такой подход позволил на имеемом компьютере произвести обучение по интересующим данным. Исходной нейронной сетью «донором», стала нейросеть *ResNet – 50*, обученная для 1000 классов на базе данных *ImageNet* [20]. В рамках эксперимента производилось обучение 3 последних слоёв нейронной сети.

Параметры обучения сверточной нейронной сети, а также архитектура представлены в табл. 2 [13].

Таблица 2

**Характеристики обучения сверточной нейронной сети [13]**

№	Параметр обучения сверточной нейронной сети	Значение
1	Архитектура сети	<i>ResNet 50</i> слоев
2	Тип преобразования сигнала в графический портрет	оконное преобразование Фурье
3	Размер входящего преобразованного радиоэфира	512*512 пикселей
4	Шаг обучения	20 у.е.
5	Тип функции активации нейрона	<i>ReduceLROnPlateau</i>
6	Количество обучаемых слоев нейронной сети	3 слоя
7	Количество выходных классов	6 шт.
8	Количество примеров для обновления	16 батчей
9	Эпох обучения	20 эпох
10	Тип обучения нейронной сети	<i>Adam</i>
11	Обучающий набор	20 000 ед.
12	Тестовый набор	19 800 ед.

По результатам обучения нейронной сети 6 классам объектов в радиозфире, была получена точность технического распознавания в 92,5% на 15 эпохе обучения, дальнейшее обучение привело к переобученной нейронной сети, которая выражалась в 98% точности распознавания объектов на обучающей выборке и снижением точности классификации тестовой выборки вплоть до 55%. За счет прописанного алгоритма весовые коэффициенты нейронной сети с наилучшими значениями классификации были сохранены [21, 22]. Динамика процесса обучения нейронной сети представлен на рис. 5 [13].

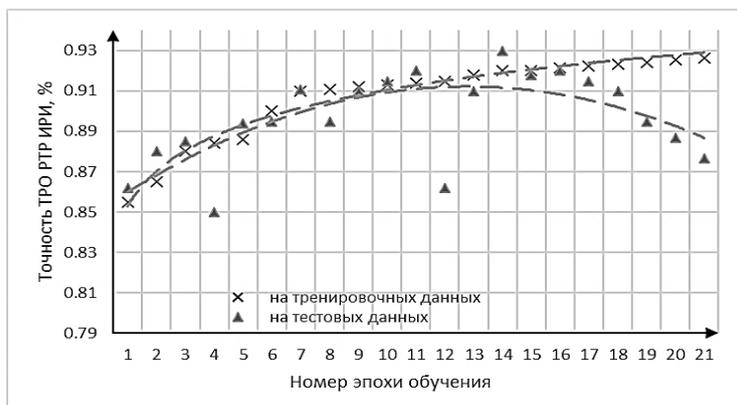


Рис. 5. Результаты обучения нейронной сети [13]

**Заключение.** В результате проведенного исследования получены следующие основные результаты: разработана модифицированная архитектура сверточной нейронной сети, специально адаптированная для обработки радиосигналов; разработана комплексная методика предобработки данных, включающая преобразование временных рядов в спектральные изображения и нормализацию амплитудных характеристик.

Проведены экспериментальные исследования на различных наборах радиосигналов, включающих: сигналы различных типов радиоэлектронных средств; различные условия помеховой обстановки; разные уровни модуляции. Установлено, что предложенный подход обеспечивает: точность распознавания до 92% при благоприятных условиях; способность к адаптации при изменении характеристик сигналов. Полученные результаты свидетельствуют о перспективности применения сверточных нейронных сетей для технического распознавания объектов при радиомониторинге. Дальнейшие исследования целесообразно направить на: расширение набора классов распознаваемых объектов; оптимизацию вычислительных затрат; разработку методов обеспечения робастности при сильных помехах.

Практическая значимость работы определяется возможностью внедрения разработанных методов в существующие системы радиомониторинга для повышения эффективности технического распознавания объектов.

#### БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Радиоэлектронная борьба в Вооруженных силах США: военно-теоретический труд. – СПб.: ООО Наукоемкие технологии, 2018. – 131 с.
2. РЛС военного назначения: Всевидящее Око в эпоху информационной войны // Серия углубленных отчетов по информатизации национальной обороны. – 2015. – № 2. – С. 25.
3. Грендер У. Лекции по теории образов. Т. 2. – М.: Мир, 1981. – С. 63-74.
4. Мазуров В.Д. Математические методы распознавания образов: учеб. пособие. – 2-е изд. – Екатеринбург: Урал, 2010. – С. 101-103.
5. Каргашин В.Л. Проблемы обнаружения и идентификации радиосигналов средств негласного контроля // Специальная техника. – 2000. – № 3–5. – С. 45-48.
6. Ильин И.С. Материалы II Конференции «Стратегия развития технологий в области искусственного интеллекта для обеспечения национальной безопасности Российской Федерации» // Искусственный интеллект и направления его развития. Кубинка, 2018. – С. 29-33.

7. Ведыхин А.А., Бурцев М.С., Витяев Е.Е. Сильный искусственный интеллект: на подступах к сверхразуму. – М.: 2021. – С. 205-215.
8. Нейронная сеть // Большая российская энциклопедия. Гл. ред. 5-е изд. – М.: Мир, 2016. – С. 189-196.
9. Зорин А.В. Распознавание лиц на основе нейронных сетей. – 43-е изд. – СПб.: Синергия Наук, 2020. – С. 510-520.
10. Bengio Y., LeCun Y., Hinton G. Deep Learning // Nature. – 2015. – No. 521. – P. 436-444.
11. Bengio Y. Foundations and Trends in Machine Learning. – 2nd ed. Vol. 2. // Learning Deep Architectures for AI / ed by Bengio Y. – Pekin: Resors, 2009. – P. 1-127.
12. Макаренко С.И. Справочник научных терминов и обозначений. – СПб.: Научное издание, 2019. – 254 с.
13. Шумков Д.В. Классификация роя неконтролируемых дронов с использованием радиочастот на основе методов машинного обучения в интересах РЭБ // Электронный рецензируемый сборник научных статей по материалам секционного заседания. – Воронеж, 2023. – С. 153-159.
14. Богомолов Л.Ю. Контроль. Диагностика. – 4-е изд. Т. № 4. – СПб.: Мир, 2013. – С. 41-45.
15. Бутырский Е.Ю. Математическое моделирование: монография. – Lambert, Oslo, 2017.
16. Quinlan J.R. Induction of Decision Trees // Machine Learning. – 1986. – No. 1. – P. 81-106.
17. Schmidhuber J. Deep Learning in Neural Networks: An Overview. Vol. 61 // Neural Networks. – Dalas, 2015. – P. 85-117.
18. Han J., Pei J., Kamber M. Data Mining: Concepts and Techniques. – New York: Elsevier, 2011. – P. 740-742.
19. Song L. Neural Information Processing. – Kentuki: Bangma, 2013. – P. 36-44.
20. Haghghat M., Zonouz S., Abdel-Mottaleb M. CloudID: Trustworthy Cloud-based and Cross-Enterprise Biometric Identification // Expert Systems with Applications. – 2015. – Vol. 42, No. 21.
21. Zadeh L. Fuzzy Logic, Neural Networks, and Soft Computing // Communications of the ACM. – 2004. – P. 77-84.
22. Glauner P. Deep Convolutional Neural Networks for Smile Recognition (MSc Thesis). – Imperial College London, Department of Computing, 2018. – URL: arXiv.com (дата обращения: 15.03.2023).
23. de Castro, Timmis J. Artificial Immune Systems: A New Computational Intelligence Approach. – Springer, 2002. – P. 57-58.

## REFERENCES

1. Radioelektronnaya bor'ba v Vooruzhennykh silakh SShA: voenno-teoreticheskiy trud [Electronic warfare in the US Armed Forces: military-theoretical work]. Saint Petersburg: OOO Naukoemkie tekhnologii, 2018, 131 p.
2. RLS voennogo naznacheniya: Vsevidyashchee Oko v epokhu informatsionnoy voyny [Military radar: The All-seeing Eye in the Age of Information Warfare], *Seriya uglublennykh otketov po informatizatsii natsional'noy oborony* [A series of in-depth reports on national defense informatization], 2015, No. 2, pp. 25.
3. Grender U. Lektsii po teorii obrazov [Lectures on the theory of images]. Vol. 2. Moscow: Mir, 1981, pp. 63-74.
4. Mazurov V.D. Matematicheskie metody raspoznavaniya obrazov: ucheb. posobie [Mathematical methods of pattern recognition: the training manual]. 2nd ed. Ekaterinburg: Ural, 2010, pp. 101-103.
5. Kargashin V.L. Problemy obnaruzheniya i identifikatsii radiosignalov sredstv neglasnogo kontrolya [Problems of detection and identification of radio signals by means of secret control], *Spetsial'naya tekhnika* [Special equipment], 2000, No. 3-5, pp. 45-48.
6. *Il'in I.S. Materialy II Konferentsii «Strategiya razvitiya tekhnologiy v oblasti iskusstvennogo intellekta dlya obespecheniya natsional'noy bezopasnosti Rossiyskoy Federatsii»* [Proceedings of the Second Conference "Strategy for the development of technologies in the field of artificial intelligence to ensure the national security of the Russian Federation"], *Iskusstvennyy intellekt i napravleniya ego razvitiya* [Artificial intelligence and the directions of its development]. Kubinka, 2018, pp. 29-33.
7. Vedyakhin A.A., Burtsev M.S., Vityaev E.E. Sil'nyy iskusstvennyy intellekt: na podstupakh k sverkhrazumu [Strong artificial intelligence: On the outskirts of superintelligence]. Moscow: 2021, pp. 205-215.
8. Neyronnaya set' [Neural network], *Bol'shaya rossiyskaya entsiklopediya* [The Great Russian Encyclopedia]. Chief editor. 5th ed. Moscow: Mir, 2016, pp. 189-196.
9. Zorin A.V. Raspoznavanie lits na osnove neyronnykh setey [Face recognition based on neural networks]. 43rd ed. Saint Petersburg, 2020, pp. 510-520.
10. Bengio Y., LeCun Y., Hinton G. Deep Learning, *Nature*, 2015, No. 521, pp. 436-444.

11. *Bengio Y.* Foundations and Trends in Machine Learning. 2nd ed. Vol. 2, *Learning Deep Architectures for AI*, ed by Bengio Y. Pekin: Resors, 2009, pp. 1-127.
12. *Makarenko S.I.* Spravochnik nauchnykh terminov i oboznacheniy [Handbook of scientific terms and designations]. Saint Petersburg: Naukoemkie tekhnologii, 2019, 254 p.
13. *Shumkov D.V.* Klassifikatsiya roya nekontroliruemyykh dronov s ispol'zovaniem radiochastot na osnove metodov mashinnogo obucheniya v interesakh REB [Classification of swarms of uncontrolled drones using radio frequencies based on machine learning methods in the interests of electronic warfare], *Elektronnyy retsenziruemyy sbornik nauchnykh statey po materialam sektsionnogo zasedaniya* [Electronic peer-reviewed collection of scientific articles based on the materials of the breakout session]. Voronezh, 2023, pp. 153-159.
14. *Bogomolov L.Yu.* Kontrol'. Diagnostika [Control. Diagnostics]. 4th ed. Vol. No. 4. Saint Petersburg: Mir, 2013, pp. 41-45.
15. *Butyrskiy E.Yu.* Matematicheskoe modelirovanie: monografiya [Mathematical modeling: monograph]. Lambert, Oslo, 2017.
16. *Quinlan J.R.* Induction of Decision Trees, *Machine Learning*, 1986, No. 1, pp. 81-106.
17. *Schmidhuber J.* Deep Learning in Neural Networks: An Overview. Vol. 61, *Neural Networks*. Dalas, 2015, pp. 85-117.
18. *Han J., Pei J., Kamber M.* Data Mining: Concepts and Techniques. New York: Elsevier, 2011, pp. 740-742.
19. *Song L.* Neural Information Processing. Kentuki: Bangma, 2013, pp. 36-44.
20. *Haghighat M., Zonouz S., Abdel-Mottaleb M.* CloudID: Trustworthy Cloud-based and Cross-Enterprise Biometric Identification, *Expert Systems with Applications*, 2015, Vol. 42, No. 21.
21. *Zadeh L.* Fuzzy Logic, Neural Networks, and Soft Computing, *Communications of the ACM*, 2004, pp. 77-84.
22. *Glauner P.* Deep Convolutional Neural Networks for Smile Recognition (MSc Thesis). Imperial College London, Department of Computing, 2018. Available at: arXiv.com (accessed 15 March 2023).
23. *de Castro, Timmis J.* Artificial Immune Systems: A New Computational Intelligence Approach. Springer, 2002, pp. 57-58.

**Шумков Денис Вадимович** – Научно-исследовательский институт оперативно-стратегических исследований ВМФ ВУНЦ ВМФ «Военно-морская академия»; e-mail: 79111111385@yandex.ru; г. Санкт-Петербург, Петергоф, Россия; тел.: +79111111385; адъюнкт.

**Титков Илья Васильевич** – ВУНЦ ВМФ «Военно-морская академия»; e-mail: tiv78@mail.ru; г. Санкт-Петербург, Россия; тел.: +79213239611; д.т.н.; профессор; зам. начальника кафедры.

**Гулевич Павел Александрович** – Научно-исследовательский институт оперативно-стратегических исследований ВМФ ВУНЦ ВМФ «Военно-морская академия»; e-mail: Pavelg-m@rambler.ru; г. Санкт-Петербург, Петергоф, Россия; тел.: +78124505079; адъюнкт.

**Shumkov Denis Vadimovich** – Scientific Research Institute of Operational and Strategic Studies of the Navy of the Russian Academy of Naval Sciences "Naval Academy"; e-mail: 79111111385@yandex.ru; St. Petersburg, Peterhof, Russia; phone: +79111111385; adjunct.

**Titkov Ilya Vasilyevich** – VUNTS of the Navy "Naval Academy"; e-mail: tiv78@mail.ru; St. Petersburg, Russia; phone: +78124961618; dr. of eng. sc.; professor; deputy head of the Department.

**Gulevich Pavel Alexandrovich** – Scientific Research Institute of Operational and Strategic Studies of the Navy VUNTS Navy "Naval Academy"; e-mail: Pavelg-m@rambler.ru; St. Petersburg, Peterhof; phone: +78124505079; adjunct.