

Современные радиотехнические и телекоммуникационные системы  
Modern radio engineering and telecommunication systems

УДК 004.032.26+537.874.4+550.837.8  
<https://doi.org/10.32362/2500-316X-2026-14-3-60-71>  
EDN LBUPEG



НАУЧНАЯ СТАТЬЯ

## Нейровизионное распознавание сигнальных радиоизображений

В.А. Кожемяко<sup>@</sup>,  
А.Д. Ярлыков

МИРЭА – Российский технологический университет, Москва, 119454 Россия  
<sup>@</sup> Автор для переписки, e-mail: kozhemyako@mirea.ru

• Поступила: 03.07.2025 • Доработана: 04.12.2025 • Принята к опубликованию: 23.03.2026

### Резюме

**Цели.** Целями работы являются: создание комбинированного нейровизионного алгоритма распознавания сигнальных радиоизображений объектов в режиме реального времени с использованием технологий машинного обучения и нейронной сети с полносвязной архитектурой и аугментацией данных; повышение вероятности правильной классификации при нейровизионной обработке сигналов.

**Методы.** В работе применены методы электродинамического моделирования, машинного обучения (линейная регрессия, классификация, случайный лес) и глубокого обучения (полносвязные нейронные сети). Применена техника бэггинга. Проведена оценка показателей точности классификации объектов и статистических критериев воспроизводимости радиоизображений.

**Результаты.** Разработан комбинированный нейровизионный метод распознавания объектов, показавший вероятность правильной классификации любого из переданных к обучению объектов с заданными форм-факторами не менее 0.97 при использовании аугментированных данных. Показано, что аугментация данных повышает вероятность правильной классификации нейронной сетью на 0.04. Полученные результаты подтвердили адекватность нейросетевых методов для задач нейровизионного распознавания объектов по сравнению с методами машинного обучения, прежде всего, при ограниченной базовой выборке объектов для обучения нейронной сети. Предложенный метод исследован для базисной классификации сферических и кубических моделей объектов в сантиметровом радиочастотном диапазоне частот.

**Выводы.** Нейронные сети с аугментацией данных демонстрируют вероятность правильной классификации свыше 0.97 в задачах нейровизионного распознавания радиоизображений в сравнении с нейронными сетями без аугментации данных (ниже на 0.04) и методами машинного обучения (ниже на 0.13). Методы машинного обучения уступают нейросетям в воспроизводимости радиоизображений, однако являются незаменимыми при ограниченных ресурсах вычислительной мощности. Для применения в реальных условиях требуются расширение базы данных за счет натуральных экспериментов и применение гибридных архитектур нейронных сетей.

**Ключевые слова:** нейровизионный метод, сигнальное радиоизображение, нейронная сеть, машинное обучение, классификация радиоизображений, линейная регрессия, метод случайного леса, электродинамическое моделирование

**Для цитирования:** Кожемяко В.А., Ярлыков А.Д. Нейровизионное распознавание сигнальных радиоизображений. *Russian Technological Journal*. 2026;14(3):60–71. <https://doi.org/10.32362/2500-316X-2026-14-3-60-71>, <https://www.elibrary.ru/LBUPEG>

**Прозрачность финансовой деятельности:** Авторы не имеют финансовой заинтересованности в представленных материалах или методах.

Авторы заявляют об отсутствии конфликта интересов.

## RESEARCH ARTICLE

# Neurovisual recognition of signal radio images

Vladislav A. Kozhemyako @,  
Alexey D. Yarlykov

MIREA – Russian Technological University, Moscow, 119454 Russia  
@ Corresponding author, e-mail: kozhemyako@mirea.ru

• Submitted: 03.07.2025 • Revised: 04.12.2025 • Accepted: 23.03.2026

### Abstract

**Objectives.** The study set out to solve the problem of radiovision classification of objects based on identified features by developing a combined neurovision algorithm for real-time recognition of signal radio images of objects using machine learning (ML) technologies and a fully connected neural network with data augmentation, as well as to improve the probability of correct classification in neurovision signal processing.

**Methods.** In the study, several methods were used: electrodynamic modeling, machine learning (linear regression, classification, and Random Forest), and deep learning (fully connected neural networks). The bootstrap aggregating (bagging) technique was also employed. An assessment of object classification accuracy metrics and statistical criteria for the reproducibility of radio images was carried out.

**Results.** A combined neurovision object recognition method was developed that demonstrated a probability of correct classification of at least 0.97 for any of the objects transmitted for training with specified form factors when using augmented data. Data augmentation was shown to increase the neural network's probability of correct classification by 0.04. The obtained results confirm the adequacy of neural network approaches compared to classical ML methods for neurovision object recognition, particularly when dealing with a limited base dataset of objects for neural network training. The proposed method was tested for basic classification of spherical and cubic object models in the centimeter radio frequency range.

**Conclusions.** Neural networks with data augmentation demonstrate a probability of correct classification exceeding 0.97 for neurovision recognition of radio images as compared to neural networks without data augmentation (0.04 lower) and traditional ML methods (0.13 lower). Although ML methods are inferior to neural networks in radio image reproducibility, they remain indispensable in cases where computational resources are limited. For real-world applications, database expansion through field experiments and the implementation of hybrid neural network architectures are required.

**Keywords:** neuroimaging method, signal radio image, neural network, machine learning, signature classification, linear regression, random forest, electrodynamic modeling

**For citation:** Kozhemyako V.A., Yarlykov A.D. Neurovisual recognition of signal radio images. *Russian Technological Journal*. 2026;14(3):60–71. <https://doi.org/10.32362/2500-316X-2026-14-3-60-71>, <https://www.elibrary.ru/LBUPEG>

**Financial disclosure:** The authors have no financial or proprietary interest in any material or method mentioned.

The authors declare no conflicts of interest.

## ВВЕДЕНИЕ

Задача обнаружения и классификации объектов в пространстве является одной из ключевых в области радиовидения. При этом, как известно, распознавание формы, размера и радиофизических идентификаторов объектов в реальном времени при помощи нейросетевых алгоритмов требует поиска комбинированного подхода в обработке сигналов, сочетающего достоинства нейронных сетей и технологий машинного обучения, которые, в ряде случаев, имеют явное превосходство перед методами оптимальной обработки [1]. Корректная классификация объектов по их радиоизображениям с градиентным, резкопереходным и неоднородным импедансом поверхностной структуры имеет критическое значения для ряда научно-практических направлений, например, при создании радиовизоров с синтезированной апертурой для серии малых спутниковых группировок дистанционного зондирования Земли типа «Кондор», предназначенных для получения радиоизображений высокого и среднего разрешения<sup>1</sup>.

Так, например, в отличие от согласованных методов вейвлет-фильтрации сверхширокополосных сигналов в частотно-временной области [2], современные решения для распознавания радиоизображений более ориентированы на обработку данных при помощи технологий машинного обучения и методов нейросетевой обработки по классифицируемым признакам, не требующих предположений о вероятностном распределении данных [1]. Нейронные сети способны одновременно анализировать множество параметров сигналов, что в разы повышает скорость обработки и снижает вероятность ошибки на 5–15%.

В работе рассматривается применение методов машинного обучения (линейная регрессия, классификация и случайный лес), а также нейронной сети с полносвязной архитектурой для распознавания радиоизображений объектов различной радиофизической природы, описываемых суперпозицией базисных стереометрических фигур. Основное внимание уделено сравнению этих методов, а также рассмотрению возможности их комбинации.

Нейровизионное исследование включает в себя три этапа. Первый – формирование базы данных сигнальных радиоизображений с использованием среды

<sup>1</sup> Руководство пользователя данными дистанционного зондирования Земли, получаемыми космической системой «Кондор-ФКА». 2023. [https://ntsomz.ru/wp-content/uploads/2023/05/2023.02.17.rukovodstvo.pol\\_zovatela.kondor-fka.dla\\_saita\\_.pdf](https://ntsomz.ru/wp-content/uploads/2023/05/2023.02.17.rukovodstvo.pol_zovatela.kondor-fka.dla_saita_.pdf). Дата обращения 14.08.2025. [User's Guide to Earth Remote Sensing Data Obtained by the Kondor-FKA Space System – 2023. Nauchnyi Tsentri Operativnogo Monitoringa Zemli (Scientific Center for Operational Monitoring of the Earth). [https://ntsomz.ru/wp-content/uploads/2023/05/2023.02.17.rukovodstvo.pol\\_zovatela.kondor-fka.dla\\_saita\\_.pdf](https://ntsomz.ru/wp-content/uploads/2023/05/2023.02.17.rukovodstvo.pol_zovatela.kondor-fka.dla_saita_.pdf). Accessed August 14, 2025. (In Russ.)]

электродинамического моделирования *Ansys HFSS*<sup>2</sup>. Второй – обучение моделей машинного обучения и создание нейровизионного алгоритма с дальнейшим обучением нейронной сети. Третий – анализ точности классификации объектов, а также статистических критериев воспроизводимости радиоизображений.

Предложенный в работе нейровизионный комбинированный метод представляет практический интерес для развития технологий цифровой обработки вторичных сигналов аэроспутниковых и наземных радиовизоров, где необходимо достижение минимизации алгоритмического времени, необходимого для распознавания объектов при ограниченных ресурсах бортовых счетно-вычислительных модулей [3].

## 1. ФОРМИРОВАНИЕ БАЗЫ ДАННЫХ РАДИОИЗОБРАЖЕНИЙ ДЛЯ НЕЙРОВИЗИОННОГО ОБУЧЕНИЯ


Как известно, при работе с методами машинного обучения либо с нейронными сетями необходима база данных для обучения модели или архитектуры, поэтому первым этапом является создание и наполнение такой базы откликов сигналов от объектов. Для проведения программно-численного эксперимента, включающего в себя классификацию объектов по форме, исходя из откликов сигналов, подготовлена база данных радиовизионных откликов от сигнатур объектов базисной формы в среде электродинамического моделирования *Ansys HFSS* [4].

Для формирования радиоизображений в среде *Ansys HFSS* построена модель эксперимента (рис. 1). Синтезированы излучающая и приемная рупорные антенны, рассчитанные на частотный диапазон 0.5–2 ГГц. Антенны равноудалены друг от друга через радиопоглощающую перегородку с поворотом апертуры под углом 60° к оси *Y*. Исследуемый объект, представленный базисной стереометрической фигурой, помещается на линию визирования, проходящую через плоскость радиопоглощающей перегородки, на расстоянии, соответствующем зоне Фраунгофера. При этом приемной антенной регистрируется рассеянная сигнатурой базисной фигуры электрическая компонента переменного поля – собственно, сигнальное радиоизображение. Для эксперимента выбраны 2 типа масштабируемых объектов: 5 вариантов куба и 5 вариантов сфер. Кубы с длинами ребер 0.35, 0.4, 0.45, 0.5 и 0.55 м, соответственно. Сферы с диаметрами 0.35, 0.4, 0.45, 0.5 и 0.55 м, соответственно. Базисные объекты представляют собой стереометрические фигуры с идеально проводящими поверхностями.


<sup>2</sup> <https://www.ansys.com/products/>. Дата обращения 14.08.2025. Accessed August 14, 2025.

В качестве радиовизионного сигнала, облучающего сигнатуру объекта, используется модель моноцикла Гаусса (рис. 2) [4]. Моноцикл формирует сверхширокополосный спектр в области 0.7–1.0 ГГц, что соответствует длинам волн 42–30 см, при масштабируемых размерах исследуемых объектов 35–55 см.


Для регистрации сигнала, рассеянного сигнатурой радиовизионного объекта, в модели эксперимента, представленной на рис. 1, необходимо формирование излучения моноцикла Гаусса, представленного на рис. 2. Расчет задаваемого амплитудного спектра моноцикла Гаусса также проводится в среде электродинамического моделирования *Ansys HFSS*. Как известно, при корректном завершении расчета



**Рис. 1.** Программно-численная электродинамическая модель эксперимента по формированию сигнальных радиоизображений объектов: 1 – приемная антенна, 2 – радиопоглощающая перегородка, 3 – излучающая антенна, 4 – радиовизионный объект, задаваемый сигнатурой базисной фигуры



(а)



(б)

**Рис. 2.** Представление моноцикла Гаусса во временной (а) и частотной (б) областях

программой *Ansys HFSS* транслируется цикл частотно-временных номограмм ближнего и дальнего поля в виде анимаций, демонстрирующих распространение радиовизионного зондирующего и рассеянного сигналов [5]. При моделировании длительность анимационного расчета задана равной 25 нс. На рис. 3 приведены стоп-кадры четырех номограмм распределения электрической компоненты рассеянного сигнатурой объекта поля радиовизионного импульса от куба с длиной ребра 0.55 м на моменты времени 4950 пс (рис. 3а), 11010 пс (рис. 3б) и сферы диаметром 0.35 м на моменты времени 5520 пс (рис. 3в) и 12030 пс (рис. 3г).

Кроме того, в модели помимо анимации номограмм распространения набегающих и рассеянных компонент электромагнитных полей представляется возможным получить выборки для построения радиопрофилей распределения рассеянного сигнатурой объекта электрического поля в выбранном направлении. Так, на рис. 4 представлен пример полученных диффузно рассеянных неоднородностями боковых поверхностей радиоизображений объектов: куба с длиной ребра 0.55 м и сферы радиусом 0.35 м [6].

Полученные радиоизображения можно экспортировать из среды *Ansys HFSS* в виде выборки данных из 965 мгновенных значений приведенной напряженности поля в мВ с шагом дискретизации 0.025 нс. Массивы программно-численных экспериментальных значений, составляющих базу нейровизионных данных, полученные для 5 сферических и 5 кубических объектов с разными форм-факторами приведены в табл. 1.

Полученная нейровизионная база данных является фреймом данных, в котором категориями для нейросетевой модели являются радиоизображения объектов, а индексами – мгновенные динамические значения сигнального радиопрофиля. Для представления и обработки нейровизионной базы данных откликов в заданный формат методами машинного обучения и нейронной сети разработана специальная программа на языке Python. Из полученной базы при помощи модуля *Pandas* (библиотека для обработки и анализа структурированных данных) радиовизионная выборка введена в программу отдельным типом данных – *DataFrame*, позволяющим хранить двумерные массивы информации, содержащие как числовые, так и строковые данные. Кроме того, использование модуля *Pandas* предоставляет исследователю доступ ко всем хранящимся данным. Однако для хранения и обработки информации модуль *Pandas* использует ресурсы памяти вычислительного устройства, т.к. работа ведется с копией исходных радиовизионных данных. Благодаря этому, полученная информация в виде *DataFrame* может использоваться для работы с методами машинного обучения и нейронными сетями [7].

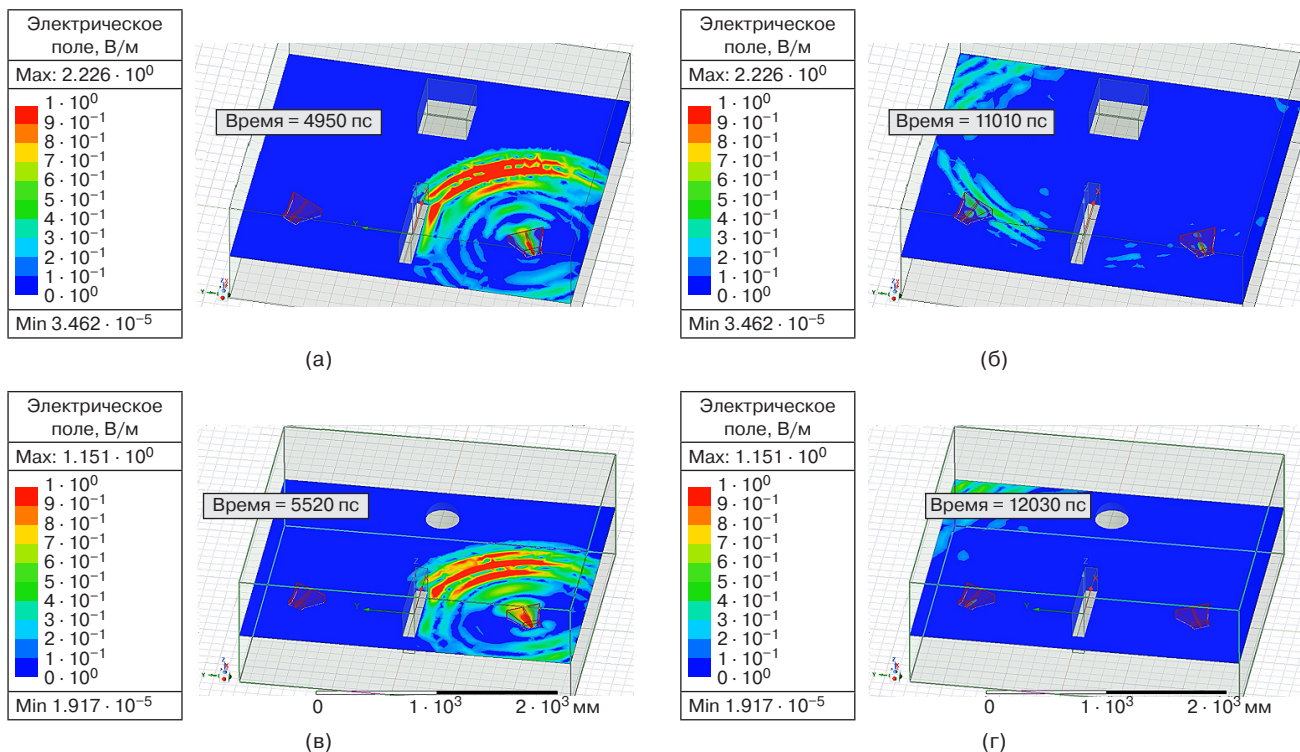


Рис. 3. Стоп-кадры номограмм распределения, рассеянного в дальней зоне поля от куба и сферы




Рис. 4. Радиоизображения кубического (а) и сферического (б) объектов, полученные с заданного направления рассеяния, определяемого законом Снеллиуса

Таблица 1. Нейровизсионные данные радиоизображений с установленными форм-факторами

Тип объекта	Сфера (с форм-фактором $D$ , м)					Куб (с форм-фактором $L$ , м)				
Форм-фактор	0.35	0.4	0.45	0.5	0.55	0.35	0.4	0.45	0.5	0.55
Индекс временного отсчета с шагом 25 пс	Мгновенные динамические значения импульсных радиоизображений, мВ									
340	-0.0195	-0.0514	0.0945	0.1146	-1.7058	-1.5478	-0.8098	1.7553	0.3806	0.3287
341	-0.1693	-0.2056	-0.0405	-0.0189	-1.5988	1.3636	-0.4782	1.1756	-0.2834	-0.3413
342	-0.3451	-0.3844	-0.1967	-0.1740	-1.4304	-1.1189	-0.0748	0.5183	-0.9570	-1.0179
343	-0.5208	-0.5632	-0.3781	-0.3554	-1.2007	-0.7913	0.3640	0.5183	-1.6125	-1.6716
344	-0.7138	-0.7572	-0.5595	-0.5367	-0.8847	-0.4636	0.8264	-0.1699	-2.2679	-2.3252
345	-0.9105	-0.9534	-0.7567	-0.7349	-0.5687	-0.0658	1.2975	-0.8719	-2.8737	-2.9239

Таблица 1. Продолжение

Тип объекта	Сфера (с форм-фактором $D$ , м)					Куб (с форм-фактором $L$ , м)				
Форм-фактор	0.35	0.4	0.45	0.5	0.55	0.35	0.4	0.45	0.5	0.55
Индекс временного отсчета с шагом 25 пс	Мгновенные динамические значения импульсных радиоизображений, мВ									
346	-1.1041	-1.1445	-0.9564	-0.9362	-0.1779	0.3665	1.7685	-1.5597	-3.4262	-3.4663
347	-1.2774	-1.3120	-1.1510	-1.1332	0.2514	0.8218	2.2189	-2.2475	-3.9123	-3.9395
348	-1.4506	-1.4796	-1.3222	-1.3076	0.7083	1.2854	2.6359	-2.8865	-4.2756	-4.2872
349	-1.5870	-1.6069	-1.4934	-1.4819	1.1808	1.7489	3.0048	-3.4709	-4.6389	-4.6349
350	-1.6879	-1.6966	-1.6241	-1.6166	1.6533	2.1925	3.2758	-3.9862	-4.8615	-4.8405
351	-1.7456	-1.7412	-1.7168	-1.7135	2.1131	2.6034	3.5468	-4.3722	-4.9819	-4.4429
...	...	...	...	...	...	...	...	...	...	...
963	-0.0575	-0.0021	-0.0202	-0.0125	-0.0124	-0.0505	0.0309	-0.0059	-0.0279	0.0012
964	-0.0501	-0.0085	-0.0173	-0.0177	-0.0102	-0.0434	0.0329	-0.0094	-0.0274	0.0008
965	-0.0501	-0.0134	-0.0173	-0.0222	-0.0102	-0.0434	0.0347	-0.0119	-0.0255	0.0008

## 2. АНАЛИЗ ЭФФЕКТИВНОСТИ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ПРИ РАСПОЗНАВАНИИ РАДИОИЗОБРАЖЕНИЙ

В рамках нейровизионного исследования проведено сравнение результатов прогнозирования, полученных с помощью трех различных методов машинного обучения. Выбор алгоритмов был обусловлен целью охватить как классические линейные модели, так и более сложные нелинейные и ансамблевые подходы: линейную регрессию, метод классификации (на основе метода опорных векторов) и метод случайного леса. Так, в работе линейная регрессия выбрана как базовый и интерпретируемый метод, метод классификации – как мощный алгоритм для работы с высокоразмерными данными, а случайный лес – в качестве эталонного ансамблевого метода, устойчивого к переобучению [8]. Модели алгоритмов машинного обучения построены на языке программирования Python с использованием библиотеки Scikit-Learn (открытая библиотека для работы с предсказательным анализом данных).

Обратимся к рассмотрению семантических признаков каждого из алгоритмов:

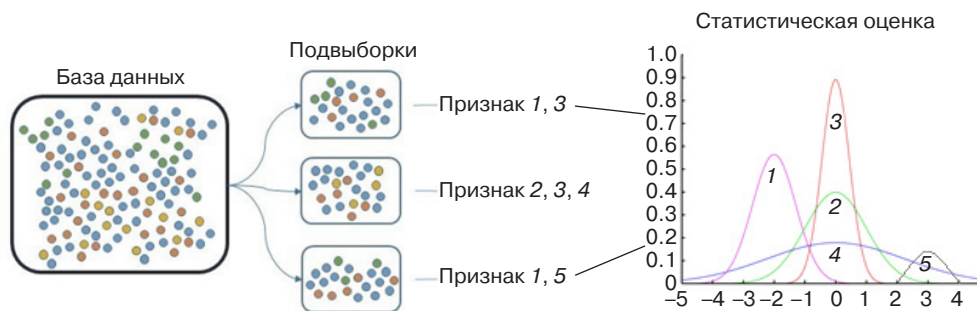
*А.* В случае с методом линейной регрессии используется уравнение вида  $Y = aX + b$ , где  $a$  и  $b$  – коэффициенты, определяемые в ходе обучения [9]. Но, т.к. выходной параметр должен быть в числовом виде, т.е. целочисленным типом данных, значения названий

искомых категорий необходимо заменить, поэтому «сфера», «куб» заменены на признаки «1» и «2» соответственно.

*Б.* Метод классификации отличается от регрессии преимущественно тем, что в регрессии нет классов, и в результате предсказывается возможная величина выходного параметра, а в классификации количество классов или категорий строго ограничено, как и ограничивается выборка для предоставления ответа [10].

*В.* Метод случайного леса – более сложная версия простых ансамблевых моделей (рис. 5). Основное отличие от предыдущих методов в том, что для обучения признаки объектов в произвольном порядке из общего набора базы данных изымаются и распределяются в более мелкие наборы данных – подвыборки (датасеты). Причем признак одного и того же объекта может встречаться в нескольких новых подвыборках [9]. Так, метод случайного леса отличается от классических ансамблей, использующих систему всех допустимых признаков, возможностью выбора признака, по которому строго будет строиться нейросетевая модель.

Как можно заметить из рис. 5, метод случайного леса интересен тем, что искусственно увеличивает базу данных откликов сигналов для обучения, снижая вероятность возникновения ошибки нейровизионного распознавания.



**Рис. 5.** Формирование датасетов методом случайного леса по строго выбранным спектрально-временным радиовизионным признакам

Для сравнения рассмотренных алгоритмов получены пять дополнительных радиоизображений объектов: три – от сферических базисов с форм-факторами 0.35, 0.375 и 0.4 м; два – от кубических с форм-факторами 0.45 и 0.475 м. При этом полученные данные подгружены в базу данных обученных программных моделей для оценки корректности нейровизионного распознавания, а также для выявления вероятностей возникновения ошибок. Результаты работы нейровизионной модели по методу машинного обучения при распознавании объекта по форм-фактору при отсутствии влияния помех приведены в табл. 2.

**Таблица 2.** Вероятность правильной классификации для обученных моделей нейровизионного распознавания объекта с заданным форм-фактором

Метод	Линейная регрессия	Классификация	Случайный лес
Вероятность правильной классификации	0.3	0.72	0.85

В рамках настоящего исследования для оценки эффективности моделей машинного обучения и нейронных сетей применяются две взаимодополняющие метрики: коэффициент корреляции и вероятность правильной классификации.

Коэффициент корреляции ( $r$ ) – мера сходства между предсказанием модели и эталонным образцом, служит пороговым критерием достоверности распознавания. Установленное пороговое значение  $r = 0.9$ , является решающим правилом: если вычисленный коэффициент превышает данный порог, результат классификации считается достоверным и принимается как корректный. В противном случае, при значении  $r < 0.9$  результат трактуется как недостаточно надежный, что указывает на потенциальную ошибку модели.

Вероятность правильной классификации определяется как доля тестовых случаев, для которых коэффициент корреляции превысил установленный порог 0.9. Данная метрика агрегирует итоговую

способность модели к точному распознаванию и вычисляется как отношение количества успешно классифицированных примеров (с корреляцией  $r \geq 0.9$ )  $N_{r \geq 0.9}$  к общему объему тестовой выборки  $N_{total}$ :

$$P = N_{r \geq 0.9} / N_{total}$$

Наивысшая вероятность правильной классификации, которой удалось достичь, применяя вышеперечисленные методы машинного обучения, равна 0.85 для метода случайного леса. Однако такая величина в отсутствие достаточной выборки данных для обучения способна привести к неудовлетворительному результату по сравнению с методами вейвлет-анализа [11].


### 3. АНАЛИЗ ЭФФЕКТИВНОСТИ ПРИМЕНЕНИЯ НЕЙРОННОЙ СЕТИ ПРИ РАСПОЗНАВАНИИ РАДИОИЗОБРАЖЕНИЙ

Архитектура разработанной нейронной сети представляет собой полностью связанную многослойную нейронную сеть, состоящую из трех слоев: двух скрытых и одного выходного слоя (рис. 6) [12]. На вход нейронная сеть принимает 965 мгновенных значений приведенной напряженности поля в мВ с шагом дискретизации 25 пс. Первый скрытый слой, состоящий из 16 нейронов, преобразует входной сигнал поступившей размерности в 16 признаков. Второй скрытый слой, состоящий из 8 нейронов, преобразует входной сигнал из 16 признаков в 8 признаков. Выходной слой, состоящий из одного нейрона, преобразует входной сигнал из 8 признаков в одно выходное значение.

Выбор трехслойной полностью связанной архитектуры нейронной сети обусловлен поиском баланса между вычислительной эффективностью и устойчивостью модели к переобучению на ограниченном объеме исходной обучающей выборки. Увеличение количества слоев привело бы к значительному росту числа обучаемых параметров, что в условиях малого размера набора данных снизило бы обобщающую способность модели. Таким образом, принятая архитектура

обеспечивает достаточную выразительную способность для выделения иерархии признаков из радиосигналов при сохранении вычислительной эффективности, необходимой для задач реального времени.

Нейронная сеть реализована с применением принципов объектно-ориентированного программирования<sup>3</sup>. Фрагмент листинга кода, описывающий нейронную сеть, представлен на рис. 7. Он демонстрирует определение класса нейронной сети (рис. 6) с тремя полносвязными слоями [13].



**Рис. 6.** Архитектура нейровизионной сети с тремя полносвязными слоями

В коде инициализируются весовые матрицы (**W1**, **W2**, **W3**) и векторы смещений (**b1**, **b2**, **b3**)

```
class NN: 1 usage
    def __init__(self, input_size):
        self.W1 = tf.Variable(tf.random.normal([input_size, 16]), name='weight1')
        self.b1 = tf.Variable(tf.zeros([16]), name='bias1')
        self.W2 = tf.Variable(tf.random.normal([16, 8]), name='weight2')
        self.b2 = tf.Variable(tf.zeros([8]), name='bias2')
        self.W3 = tf.Variable(tf.random.normal([8, 1]), name='weight3')
        self.b3 = tf.Variable(tf.zeros([1]), name='bias3')

    def forward(self, x): 3 usages (1 dynamic)
        z1 = tf.matmul(x, self.W1) + self.b1
        a1 = tf.nn.relu(z1)
        z2 = tf.matmul(a1, self.W2) + self.b2
        a2 = tf.nn.relu(z2)
        z3 = tf.matmul(a2, self.W3) + self.b3
        return tf.sigmoid(z3)

@property 2 usages (2 dynamic)
def trainable_variables(self):
    return [self.W1, self.b1, self.W2, self.b2, self.W3, self.b3]
```

**Рис. 7.** Фрагмент листинга кода, описывающий нейронную сеть

<sup>3</sup> Босенко Т.М. *Основы объектно-ориентированного анализа и программирования в Python: учебно-методическое пособие*. М.: Московский городской педагогический университет; 2023, 80 с. [Bosenko T.M. *Osnovy ob'ektno-orientirovannogo analiza i programmirovaniya v Python (Fundamentals of Object-Oriented Analysis and Programming in Python)*: A study guide. Moscow: Moscow City Pedagogical University; 2023, 80 p. (In Russ.)]

<sup>4</sup> Neural network – нейронная сеть.

соответствующих размерностей. Функция forward, являющаяся методом класса NN<sup>4</sup>, реализует прямое распространение сигнала через слои с функциями активации ReLU и сигмоидальной функцией на выходе.

В качестве функции активации для нейронов 1-го и 2-го слоя выбран оператор  $\text{ReLU} = \begin{cases} x, & x > 0, \\ 0, & x < 0 \end{cases}$  (сокр. от англ. Rectified Linear Unit) [14].

В первую очередь, это обусловлено тем, что оператор ReLU позволяет работать с массивами данных, вычислительно эффективен, устраняет проблему затухающих градиентов и способствует разреженным активациям.

Матрицы весов **W1**, **W2**, **W3** инициализируются случайными значениями, а векторы смещений **b1**, **b2**, **b3** инициализируются нулями.

Прохождение данных через нейронную сеть осуществляется последовательно через три слоя: на первом слое входные данные подвергаются линейному преобразованию посредством умножения на матрицу весов **W1** с добавлением вектора смещений **b1**, после чего к результату применяется нелинейная функция активации ReLU; на втором слое выходные данные предыдущего слоя умножаются на матрицу



Рис. 8. Схема комбинированного алгоритма распознавания радиоизображений

весов  $W_2$  с добавлением вектора смещений  $b_2$  и аналогично применяется функция ReLU; на выходном слое полученные признаки преобразуются путем умножения на матрицу весов  $W_3$  с добавлением смещения  $b_3$ , а итоговое значение нормализуется с помощью сигмоидальной функции активации для получения вероятности принадлежности к целевому классу [12].

Обучение сети проводится с помощью алгоритма обратного распространения ошибки. В качестве функции определения потерь используется бинарная перекрестная энтропия, которая измеряет разницу между предсказанными вероятностями и истинными метками. Свойство `trainable_variables` возвращает список всех обучаемых параметров для оптимизатора. В качестве оптимизатора применен алгоритм Adam (сокр. от англ. Adaptive Moment Estimation). Adam является гибридным алгоритмом оптимизации, он вычисляет адаптивные скорости обучения для каждого отдельно взятого параметра, используя оценки первого и второго моментов градиентов. Самым главным преимуществом Adam является возможность работы с большими данными [15]. Обучающая выборка данных предварительно увеличена на 30% в коде программы при помощи метода машинного обучения бэггинг [9].

Процесс обучения включает следующие этапы: прямой проход – вычисление предсказаний для входных значений; вычисление ошибки – сравнение предсказаний с истинными значениями; обратный проход – расчет градиентов, т.е. направлений изменения параметров [12]; обновление весов – корректировка параметров сети для уменьшения ошибки.

Для удаления лишней размерности из предсказаний использована функция `squeeze`, необходимая для корректного вычисления потерь, что позволяет согласовать размерности тензоров прогнозов и истинных значений для расчета функции потерь [16].

Оценку качества предсказаний модели выполняет функция `binary_crossentropy`, которая вычисляет бинарную кроссэнтропию между истинными метками и предсказанными значениями. Это мера различия между двумя распределениями вероятностей позволяет оценить эффективность модели в задачах бинарной классификации, количественно определяя расхождение распределений вероятностей, предсказанных моделью, и истинным распределением меток.

В качестве базы данных для обучения разработанной модели нейронной сети использовалась база нейровизионных данных радиоизображений объектов, представленная в табл. 1. Для проверки корректности вычислений и оценки обобщающей способности модели был создан независимый тестовый бенчмарк объемом в пять радиоизображений: три – от сферических базисов с форм-факторами 0.35, 0.375 и 0.4 м; два – от кубических с форм-факторами 0.45 и 0.475 м. Чрезвычайно важно, что тестовые объекты с промежуточными форм-факторами 0.375 и 0.475 м не были представлены в обучающей выборке, что обеспечивало объективность валидации. Хотя все данные были синтезированы в *Ansys HFSS*, тестовый набор состоял из принципиально новых для модели объектов. Представленная нейронная сеть показала вероятность правильной классификации 0.97 на независимом тестовом наборе. Вероятнее всего такой результат обусловлен тем, что набор данных для обучения – меньшего объема, чем необходимый размер, однако, если не проводить искусственное увеличение выборки данных при помощи бэггинга, то эта же нейронная сеть показывает вероятность правильной классификации 0.93, что на 0.04 меньше. Это существенно повышает итоговую точность модели и доказывает эффективность использования бэггинга для борьбы с переобучением на малых выборках.

Таким образом, разработанный комбинированный алгоритм реализует синергетический подход к обработке радиовизионных данных, последовательно объединяя методы машинного обучения и нейронную сеть. Как показано на схеме (рис. 8), процесс начинается с синтеза исходных данных в *Ansys HFSS* и их преобразования в объект `DataFrame`, после чего ключевой этап комбинирования интегрирует технику бэггинга для аугментации данных и полносвязную нейронную сеть для классификации. Такое сочетание позволяет преодолеть ограничения малого объема исходной выборки за счет искусственного расширения набора данных и одновременно использовать высокую распознающую способность нейросетевой модели, что в совокупности обеспечивает достижение высокой точности классификации.

## ЗАКЛЮЧЕНИЕ

Разработан и исследован комбинированный нейровизионный метод распознавания сигнальных радиоизображений объектов на основе машинного обучения и нейронной сети. Метод, сочетающий полностью связанную нейронную сеть и метод машинного обучения бэггинг, позволяет в режиме реального времени классифицировать объекты базисной стереометрической формы по их радиоизображениям, синтезированным в сантиметровом диапазоне частот. Экспериментальные исследования алгоритма проведены на основе базы данных радиовизионных окликов, сгенерированной при помощи построенного программно-численного электродинамического стенда в среде *Ansys HFSS*, позволяющего синтезировать базу данных сигнальных радиоизображений для объектов с заданными форм-факторами и распознавать их при помощи разработанного в работе программного обеспечения на базе нейровизионной сети с тремя полностью связанными слоями и аугментацией данных.

На основе сравнительного анализа методов машинного обучения и нейронных сетей получены экспериментальные результаты, подтверждающие эффективность предложенного комбинированного подхода для задач радиовидения:

- разработана трехслойная полностью связанная нейронная сеть с функциями активации ReLU и sigmoid, которая достигла вероятности правильной классификации сферических и кубических объектов 0.97;
- установлено, что применение техники аугментации данных (бэггинг) для увеличения обучающей выборки на 30% позволяет повысить вероятность правильной классификации нейронной сетью на 0.04 (с 0.93 до 0.97), что доказывает

эффективность для борьбы с переобучением на малых выборках;

- показано, что из рассмотренных методов машинного обучения алгоритм случайного леса обеспечивает наибольшую вероятность правильной классификации (0.85), что на 0.55 выше, чем у линейной регрессии (0.3), и на 0.12 выше, чем у метода классификации (0.72), однако уступает нейросетевым методам;
- разработан комбинированный алгоритм, интегрирующий технику бэггинга и нейронную сеть с аугментацией данных для классификации, который позволяет достичь вероятности правильной классификации 0.97.

Предложенный комбинированный метод демонстрирует эффективность за счет синергетического использования алгоритма машинного обучения (бэггинг) для аугментации данных и нейронной сети для классификации, что позволяет преодолеть ограничения каждого из методов в отдельности. Вместе с тем, комбинированный метод имеет ряд ограничений, включая зависимость от адекватности синтезированных данных, необходимость валидации объектов сложной геометрии в условиях влияния помех, что определяет направления для дальнейших исследований.

### Вклад авторов

**В.А. Кожемяко** – формулировка целей и задач, практическое исследование комбинированного нейровизионного метода и алгоритма распознавания сигнальных радиоизображений.

**А.Д. Ярлыков** – постановка плана исследований, формулировка выводов.

### Authors' contributions

**V.A. Kozhemyako** – formulation of aims and objectives, practical research of the combined neurovision method and algorithm for recognizing signal radio images.

**A.D. Yarlykov** – formulation of the research plan, formulation of conclusions.

## СПИСОК ЛИТЕРАТУРЫ

1. Терлецкий А.С., Терлецкая Е.С. *Нейронные сети и искусственный интеллект: Основы нейронных сетей на языке Python*. Липецк: Липецкий государственный педагогический университет имени П.П. Семенова-Тянь-Шанского; 2023, 76 с. <https://www.elibrary.ru/ugipee>
2. Торгаев С.Н., Лежнина И.А., Шульга И.Д. *Практическое руководство по цифровой обработке сигналов: цифровые фильтры и обработка ЭКГ сигналов*. Томск: ООО «СТТ»; 2020, 112 с. <https://www.elibrary.ru/rupfct>
3. Царегородцев М.А. Многопоточная численная реализация криптографических алгоритмов параллельного действия для защиты конфиденциальной информации в оборонно-промышленных комплексах при ее обработке, хранении и передаче в облачное хранилище больших данных. *Альманах Пермского военного института войск национальной гвардии*. 2023;4(12):104–112. <https://www.elibrary.ru/vvtbii>
4. Курушин А.А. *Гибридное моделирование в HFSS ANSYS: учебное пособие*. М.: СОЛОН-Пресс; 2023, 292 с.
5. Банков С.Е., Курушин А.А. *Расчет антенн и СВЧ структур с помощью HFSS Ansoft*. М.: ЗАО «НПП «РОДНИК»; 2009, 256 с.
6. Кожемяко В.А. Получение отклика сигнала от объекта в САПР Ansys. В сб.: *Актуальные проблемы и перспективы развития радиотехнических и инфокоммуникационных систем («Радиоинфоком-2024»)*: Сборник научных статей по материалам VIII Международной научно-практической конференции. Москва, 18–22 ноября 2024 г. М.: РТУ МИРЭА; 2024. С. 381–384. <https://www.elibrary.ru/mwzoxe>

7. Иванова В.Ю., Соловьев Д.О. Обзор методов обработки больших данных с использованием Apache Spark, библиотеки Pandas и SQL. *Наукосфера*. 2024;5(1):43–47. <https://doi.org/10.5281/zenodo.11241367>, <https://www.elibrary.ru/uljwcm>
8. Хабиб Ж.М.Т., Погуда А.А. Сравнение методов анализа настроений глубокого обучения, включая LSTM и машинное обучение. *Открытое образование*. 2023;27(4):60–71. <https://doi.org/10.21686/1818-4243-2023-4-60-71>
9. Казанцев Т. *Искусственный интеллект и машинное обучение. Основы программирования на Python*. ЛитРес: Самиздат; 2020, 123 с.
10. Большаков Н.И., Сидорова Е.В. Сравнительный анализ методов машинного обучения для задач классификации данных. *Математические методы в технологиях и технике*. 2023;8:66–71. <https://elibrary.ru/zdgmrk>
11. Kouemou G., Opitz F. Impact of Wavelet-Based Signal Processing Methods on Radar Classification Systems Using Hidden Markov Models. In: *2008 International Radar Symposium*. Wroclaw, Poland. 2008. <https://doi.org/10.1109/IRS.2008.4585763>
12. Шевченко А.С., Самарин В.А. *Нейронные сети: учебное пособие*. М.: Ай Пи Ар Медиа; 2025, 181 с.
13. Смирнов Е.Е., Костылева В.В., Муртазина А.Р., Разин И.Б. Сравнение сверточных и полносвязных нейронных сетей применительно к задачам распознавания изображений. *Известия высших учебных заведений. Технология текстильной промышленности*. 2023;5(407):236–242. <https://elibrary.ru/gvpmmpa>
14. Парамонов А.А., Нгуен В., Нгуен М. Многозадачная нейронная сеть в задаче распознавания вида QAM- и PSK-модуляции в условиях параметрической априорной неопределенности. *Russian Technological Journal*. 2023;11(4):49–58. <https://doi.org/10.32362/2500-316X-2023-11-4-49-58>
15. Абдулкадиров Р.И., Алиханов А.А., Айдамиров Н.О., Бабаян Р.А., Дадалян А.А., Давыдов Н.М. Сравнительный анализ алгоритмов оптимизации на примере различных тестовых функций. В сб.: *Высокопроизводительные вычисления для решения прикладных задач: Сборник материалов XII (69-й) ежегодной научно-практической конференции студентов, преподавателей и молодых ученых Северо-Кавказского федерального университета, Ставрополь, 14–27 апреля 2025 года*. Ставрополь; 2025. С. 17–21. <https://elibrary.ru/dqdcfh>
16. Гаунов С.Р., Баймурадов У.Г., Ситников С.Ю. Машинное обучение на Python: использование библиотек Tensorflow и Scikit-Learn. *Экономика и управление: проблемы, решения*. 2024;8(12-153):72–81. <https://doi.org/10.36871/ek.up.p.r.2024.12.08.009>

## REFERENCES

1. Terletskii A.S., Terletskaya E.S. *Neironnye seti i iskusstvennyi intellekt: Osnovy neironnykh setei na yazyke Python (Neural Networks and Artificial Intelligence: Fundamentals of Neural Networks in Python)*. Lipetsk: Lipetsk State Pedagogical P. Semenov-Tyan-Shansky University; 2023, 76 p. (In Russ.). <https://www.elibrary.ru/ugipee>
2. Torgaev S.N., Lezhnina I.A., Shul'ga I.D. *Prakticheskoe rukovodstvo po tsifrovoi obrabotke signalov: tsifrovye fil'try i obrabotka EHKG signalov (A Practical Guide to Digital Signal Processing: Digital Filters and ECG Signal Processing)*. Tomsk: STG; 2020, 112 p. (In Russ.). <https://www.elibrary.ru/rupfct>
3. Tsaregorodtsev M.A. Multithreaded numerical implementation of cryptographic algorithms of parallel action for protecting confidential information in defense-industrial complexes during its processing, storage and transmission to the cloud storage of big data. *Al'manakh Permskogo voennogo instituta voisk natsional'noi gvardii = Almanac of the Perm Military Institute of the National Guard Troops*. 2023;4(12):104–112 (in Russ.). <https://www.elibrary.ru/vvtbii>
4. Kurushin A.A. *Gibridnoe modelirovanie v HFSS ANSYS (Hybrid Modeling in HFSS ANSYS): A tutorial*. Moscow: SOLON-Press; 2023, 292 p. (In Russ.).
5. Bankov S.E., Kurushin A.A. *Raschet antenna i SVCh struktur s pomoshch'yu HFSS Ansoft (Calculation of Antennas and Microwave Structures using HFSS Ansoft)*. Moscow: RODNIK; 2009, 256 p. (In Russ.).
6. Kozhemyako V.A. Getting a signal response from an object in Ansys CAD. In: *Actual Problems and Prospects for the Development of Radio Engineering and Infocommunication Systems ("Radioinfocom-2024")*: Collection of scientific articles based on the materials of the 8th International Scientific and Practical Conference. Moscow: RTU MIREA; 2024. P. 381–384 (in Russ.). <https://www.elibrary.ru/mwzoxe>
7. Ivanova V.Yu., Solovyev D.O. Overview of Big Data Processing Methods Using Apache Spark, Pandas Library, and SQL. *Naukosfera = Naukosphere*. 2024;5(1):43–47 (in Russ.). <https://doi.org/10.5281/zenodo.11241367>, <https://www.elibrary.ru/uljwcm>
8. Habib J.M.T., Poguda A.A. Comparison of Deep Learning Sentiment Analysis Methods, Including LSTM and Machine Learning. *Otkrytoe Obrazovanie = Open Education*. 2023;27(4):60–71 (in Russ.). <https://doi.org/10.21686/1818-4243-2023-4-60-71>
9. Kazantsev T. *Iskusstvennyi intellekt i mashinnoe obuchenie. Osnovy programmirovaniya na Python (Artificial Intelligence and Machine Learning. Fundamentals of Python Programming)*. LitRes: Samizdat; 2020, 123 p. (In Russ.).
10. Bolshakov N.I., Sidorova E.V. Comparative Analysis of Machine Learning Methods for Problems of Data Classification. *Matematicheskie metody v tekhnologiyakh i tekhnike = Mathematical Methods in Technology and Engineering*. 2023;8: 66–71 (in Russ.). <https://elibrary.ru/zdgmrk>
11. Kouemou G., Opitz F. Impact of Wavelet-Based Signal Processing Methods on Radar Classification Systems Using Hidden Markov Models. In: *2008 International Radar Symposium*. Wroclaw, Poland. 2008. <https://doi.org/10.1109/IRS.2008.4585763>
12. Shevchenko A.S., Samarina V.A. *Neironnye seti (Neural Networks): A Tutorial*. Moscow: Ai Pi Ar Media; 2025, 181 p. (In Russ.).
13. Smirnov E.E., Kostyleva V.V., Murtazina A.R., Razin I.B. Comparison of Convolutional and Fully Connected Neural Networks in Relation to Image Recognition Tasks. *Izvestiya vysshikh uchebnykh zavedenii. Tekhnologiya tekstil'noi promyshlennosti = Textile Industry Technology. Series: Proceedings of Higher Educational Institutions*. 2023;5(407): 236–242 (in Russ.). <https://elibrary.ru/gvpmmpa>

14. Paramonov A.A., Nguyen V.M., Nguyen M.T. Multi-task neural network for solving the problem of recognizing the type of QAM and PSK modulation under parametric a priori uncertainty. *Russian Technological Journal*. 2023;11(4):49–58. <https://doi.org/10.32362/2500-316X-2023-11-4-49-58>
15. Abdulkadirov R.I., Alikhanov A.A., Aidamirov N.O., Babayan R.A., Dadalyan A.A., Davydov N.M. Comparative analysis of optimization algorithms using various test functions. In: *High-Performance Computing for Solving Applied Problems: Collection of materials of the 12th (69th) Annual Scientific and Practical Conference of Students, Teachers, and Young Scientists of the North Caucasus Federal University*. Stavropol; 2025. P. 17–21 (in Russ.). <https://elibrary.ru/dqdcfh>
16. Gaunov S.R., Baimuradov U.G., Sitnikov S.Yu. Machine learning in Python: using Tensorflow and Scikit-Learn libraries. *Ehkonomika i upravlenie: problemy, resheniya = Economics and Management: Problems, Solutions*. 2024;8(12-153):72–81 (in Russ.). <https://doi.org/10.36871/ek.up.p.r.2024.12.08.009>

#### Об авторах

**Кожемяко Владислав Александрович**, ассистент, кафедра радиоволновых процессов и технологий, Институт радиоэлектроники и информатики, ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: kozhemyako@mirea.ru. SPIN-код РИНЦ 4210-0353, <http://orcid.org/0009-0009-8512-2288>

**Ярлыков Алексей Дмитриевич**, к.т.н., старший преподаватель, кафедра радиоволновых процессов и технологий, Институт радиоэлектроники и информатики, ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: yarlykov@mirea.ru. Scopus Author ID 57290652000, SPIN-код РИНЦ 3450-1587, <https://orcid.org/0000-0002-7232-8588>

#### About the Authors

**Vladislav A. Kozhemyako**, Assistant, Department of Radio Wave Processes and Technologies, Institute of Radio Electronics and Informatics, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: kozhemyako@mirea.ru. SPIN-code RSCI 4210-0353, <http://orcid.org/0009-0009-8512-2288>

**Alexey D. Yarlykov**, Cand. Sci. (Eng.), Senior Lecturer, Department of Radio Wave Processes and Technologies, Institute of Radio Electronics and Informatics, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: yarlykov@mirea.ru. Scopus Author ID 57290652000, RSCI SPIN-code 3450-1587, <https://orcid.org/0000-0002-7232-8588>