

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ КОСМИЧЕСКИМИ АППАРАТАМИ,
ОБРАБОТКА ИНФОРМАЦИИ И СИСТЕМЫ ТЕЛЕМЕТРИИ.
ДИСТАНЦИОННОЕ ЗОНДИРОВАНИЕ ЗЕМЛИ

УДК 004.8 DOI 10.30894/issn2409-0239.2023.10.3.32.38 EDN SXSTMI

**Метод классификации сигналов космических аппаратов
с использованием нейронных сетей**

Д. В. Горбунов, *orcid: 0000-0002-4646-2636, darkwen3@mail.ru*

МГТУ им. Н. Э. Баумана, Москва, Российская Федерация

М. А. Кудрявцев, *orcid: 0000-0001-7034-8270, spin: 8671-1745, kudryavtsev@bmstu.ru*

МГТУ им. Н. Э. Баумана, Москва, Российская Федерация

К. Л. Тассов, *spin: 1141-6778, ktassov@bmstu.ru*

МГТУ им. Н. Э. Баумана, Москва, Российская Федерация

М. В. Филиппов, *к. т. н., доцент, spin 3781-5276, filippovmv@bmstu.ru*

МГТУ им. Н. Э. Баумана, Москва, Российская Федерация

Аннотация. В связи со стремительным развитием космических технологий задачи классификации сигналов космических аппаратов и обработки информации становятся как никогда актуальными. Одним из возможных решений задачи классификации могут быть нейронные сети, способные убрать шумы и произвести классификацию сигналов космических аппаратов.

Авторами предложен метод классификации сигналов космических аппаратов, основанный на действии нейронных сетей. Сигналы с шумом поступают на радиотелескопы, и для их обработки необходимо понять, от какого спутника пришел сигнал. В рамках метода предложен алгоритм, включающий в себя этап предварительной обработки сигнала и этап классификации нормированного сигнала. Метод может быть использован в системах контроля космического пространства как вспомогательный для определения типа спутника, от которого пришел сигнал, для его дальнейшей обработки и получения необходимой информации. В статье рассмотрены сравнение, предварительная обработка и классификация сигналов космических аппаратов, приведена оценка результатов полученной точности для валидационного и тренировочного наборов, приведена структура нейронной сети, а также структура используемого программного обеспечения.

Ключевые слова: классификация сигналов космических аппаратов, нейронные сети, обработка сигнала, сравнение сигналов

**A Method for Classifying Spacecraft Signals
Using Neural Networks**

D. V. Gorbunov, *orcid: 0000-0002-4646-2636, darkwen3@mail.ru*

Bauman Moscow State Technical University, Moscow, Russian Federation

M. A. Kudryavtsev, *spin: 8671-1745, orcid: 0000-0001-7034-8270, kudryavtsev@bmstu.ru*

Bauman Moscow State Technical University, Moscow, Russian Federation

K. L. Tassov, *spin: 1141-6778, ktassov@bmstu.ru*

Bauman Moscow State Technical University, Moscow, Russian Federation

M. V. Filippov, *Cand. Sci. (Engineering), Associate Professor, spin: 3781-5276, filippovmv@bmstu.ru*

Bauman Moscow State Technical University, Moscow, Russian Federation

Abstract. In connection with the rapid development of space technologies, the problems of classifying signals from spacecraft and processing information are becoming more relevant than ever. One of the possible solutions to the classification problem can be neural networks that can remove noise and classify spacecraft signals.

The authors propose a method for classifying spacecraft signals based on neural networks. Noisy signals arrive at radio telescopes, and in order to process them, it is necessary to the satellite that is the origin of the signal. Within the framework of the method, an algorithm is proposed that includes the stage of signal preprocessing and the stage of classifying the normalized signal. The method can be used in space monitoring systems as an auxiliary method for determining the type of satellite the signal origin belongs to for its further processing and obtaining the necessary information. The article discusses the comparison, preprocessing and classification of spacecraft signals, evaluates the results of the obtained accuracy for the validation and training sets, shows the structure of the neural network, as well as the structure of the software used.

Keywords: classification of spacecraft signals, neural networks, signal processing, signal comparison

Введение

С каждым годом различные организации, связанные с космосом, проектируют и создают новые спутники, которые играют важную роль в повышении качества жизни. С помощью спутников контролируют окружающую среду, спасают жизни людей, предсказывают погоду, изучают планеты и галактики, живые организмы; также при использовании спутников реализуется навигация, телефонная связь и доступ в Интернет, производится мониторинг солнечной активности.

Спутники излучают сигнал [1], который принимается радиотелескопом и обрабатывается. Перед обработкой необходимо определить, от какого спутника пришел сигнал, чтобы применить специальные алгоритмы для обработки и получения информации. Для этого необходимо классифицировать сигнал.

К сожалению, в открытом доступе нет решения задачи классификации временных, комплексных, зашумленных сигналов.

В статье рассмотрен метод классификации сигналов космических аппаратов с использованием нейронной сети. Предложена модифицированная сверточная нейронная сеть для классификации временных, комплексных, зашумленных сигналов.

Постановка задачи

Рассмотрим задачу классификации сигналов [2] космических аппаратов. На вход алгоритму подается файл с сигналом. Сигнал должен быть временным, комплексным, непериодическим и иметь размер $200\,000 \times 2$ значений, в сигнале может присутствовать шум. Выходом алгоритма является класс данного сигнала. Важно отметить, что сверточные

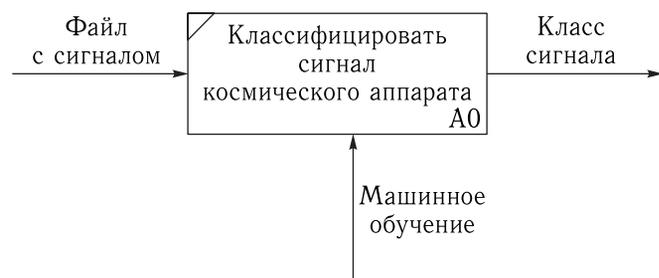


Рис. 1. Диаграмма верхнего уровня. Постановка задачи

нейронные сети [3] чаще всего применяются для задачи классификации. Постановка задачи представлена на рис. 1.

Основные требования к системе:

- устойчивость к шумам и помехам,
- работа с комплексными сигналами.

Метод классификации сигналов космических аппаратов

1. Описание сверточной нейронной сети

Сверточная нейронная сеть [4] — одна из форм многослойных нейронных сетей [5]. Они разрабатывались для работы с изображениями. Именно этот тип нейронных сетей стал основным в компьютерном зрении и распознавании образов. Сейчас сверточные нейронные сети используются для распознавания речи, обработки изображений, текста и так далее. Сверточные нейронные сети устойчивы к искажениям и перемещениям.

Структура [6] таких сетей состоит из чередования сверточных, пулинговых, полносвязных слоев. Чередование сверточных и подвыборочных происходит в начале, а полносвязных — в конце. Сверточный и подвыборочный слои формируют входной вектор признаков для многослойного перцептрона. На рис. 2 показан пример сверточной нейронной сети.

2. Классификация сигналов с использованием модифицированной сверточной нейронной сети

В названии сети лежит ее основная операция — свертка. На вход каждого нейрона подается не весь сигнал, а только некоторая область, причем на каждый нейрон своя. Каждый нейрон обрабатывает небольшой кусочек предыдущего слоя, обобщает информацию и передает ее следующему слою. Такой подход сокращает объем вычислений.

Ядро (фильтр) представляет из себя вектор весов. Ядро «скользит» над одномерным сигналом и производит операцию умножения с частью данных, над которой оно сейчас находится, далее выполняется суммирование всех полученных значений. На рис. 3 показан пример свертки.

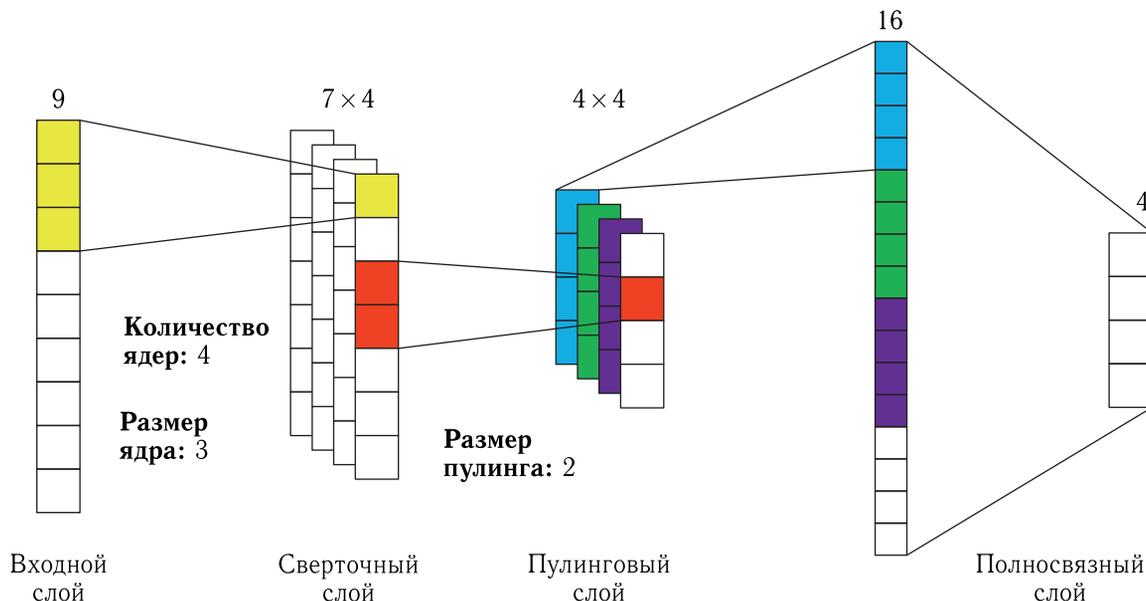


Рис. 2. Сверточная нейронная сеть

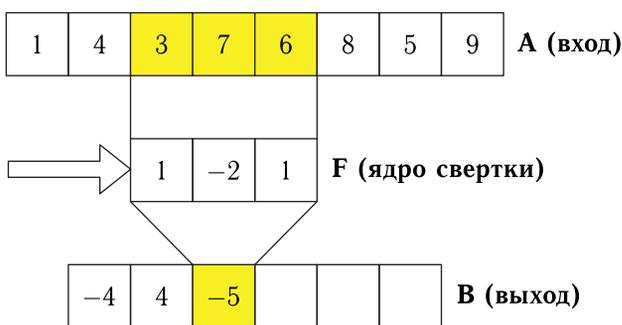


Рис. 3. Пример свертки с размером ядра 3

Ядро повторяет данную процедуру с каждой частью данных, над которой оно сейчас находится, преобразуя одномерный вектор в другой одномерный вектор — вектор признаков.

Ядро свертки [7] кодирует какой-либо признак. Каждое ядро формирует отдельный вектор признаков. Нейроны одного вектора признаков имеют одинаковые весовые коэффициенты. Это позволяет находить одинаковый признак в сигнале. Используется несколько ядер, благодаря которым получается стек независимых векторов признаков одного уровня.

Для комплексного сигнала [8] необходимо 2 канала: канал для действительных чисел и канал мнимых чисел. Для каждого входного канала необходимо одно ядро. Эти ядра имеют больший вес, чтобы уделять больше внимания входным каналам.

Каждая из версий, обработанная ядром, суммируется вместе для формирования одного канала. На рис. 4 показано применение фильтра к комплексному сигналу.

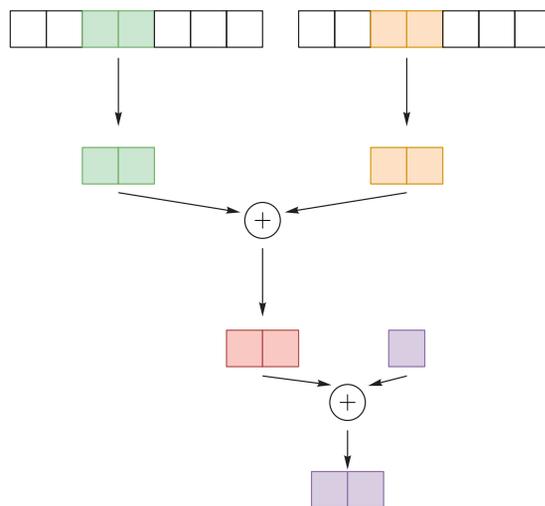


Рис. 4. Применение фильтра к комплексному сигналу

«Подобно сверточному слою, пулинговый слой необходим для уменьшения размера свернутого элемента в пространстве. Это помогает уменьшить вычислительную мощность, необходимую для обработки данных, за счет уменьшения размерности. Кроме того, он выступает в роли шумоподавителя»

и используется для извлечения доминирующих признаков. Максимальный пулинг возвращает максимальное значение из части сигнала, покрываемой ядром» [14]. Пример максимального пулинга показан на рис. 5.

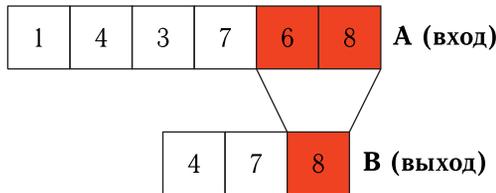


Рис. 5. Пример максимального пулинга с размером пула 2

«Нейроны полносвязного слоя соединены со всеми нейронами предыдущего слоя, что означает, что каждый нейрон полносвязного слоя может взаимодействовать с любым нейроном предыдущего слоя. Поэтому полносвязные слои очень важны для финальной части нейронных сетей, где они используются для классификации данных» [15].

Перед классификацией сигнала необходимо его нормализовать [9]. Нормировка сигнала заключается в том, что все значения должны лежать в интервале $[-1; 1]$. Далее происходит классификация сигнала с использованием модифицированной сверточной нейронной сети.

Разработана следующая структура сверточной нейронной сети:

[INPUT] → [CONV, RELU] → [MAXPOOLING] → [CONV, RELU] → [CONV, RELU] → [MAXPOOLING] → [CONV, RELU] → FLATTEN → [DENSE, SIGMOID].

1. Входной слой (INPUT) — 2 канала: канал для действительных чисел и канал мнимых чисел. На вход поступает комплексный, временной сигнал космического аппарата, размерность которого $200\,000 \times 2$.

2. Сверточный слой с функцией активацией ReLU [10], график которой показан на рис. 6 (CONV, RELU), — выделяет базовые паттерны, используя 100 ядер размерностью 9, в результате чего получается тензор размером $199\,992 \times 100$.

3. Пулинговый слой (MAXPOOLING) — размерность пула: 4, с его помощью размерность снижается до 49 998.

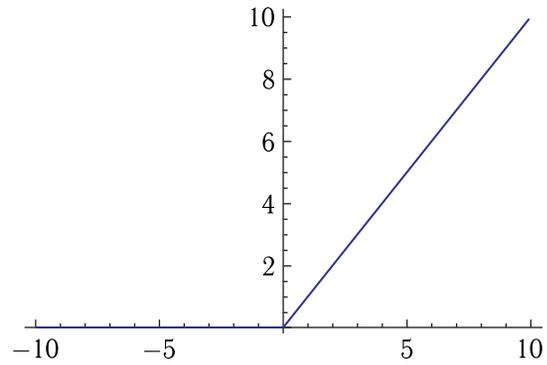


Рис. 6. Функция активации ReLU

4. Сверточный слой с функцией активацией ReLU (CONV, RELU) — выделяет базовые паттерны, используя 100 ядер размерностью 9, в результате чего получается тензор размером $49\,990 \times 100$.

5. Сверточный слой с функцией активацией ReLU (CONV, RELU) — выделяет базовые паттерны, используя 100 ядер размерностью 9, в результате чего получается тензор размером $49\,982 \times 100$.

6. Пулинговый слой (MAXPOOLING) — размерность пула: 4, с его помощью размерность снижается до $24\,991 \times 100$.

7. Сверточный слой с функцией активацией ReLU (CONV, RELU) — выделяет базовые паттерны, используя 100 ядер размерностью 9, в результате чего получается тензор размером $24\,983 \times 100$.

8. Слой, преобразующий данные в одномерный вектор (FLATTEN), — преобразует тензор размером $24\,983 \times 100$ в вектор размерностью $2\,498\,300 \times 1$ с помощью последовательного добавления данных в одномерный вектор.

9. Полносвязный слой с функцией активации логистическая Sigmoid [11], график которой показан на рис. 7 (DENSE, SIGMOID), — выполняет

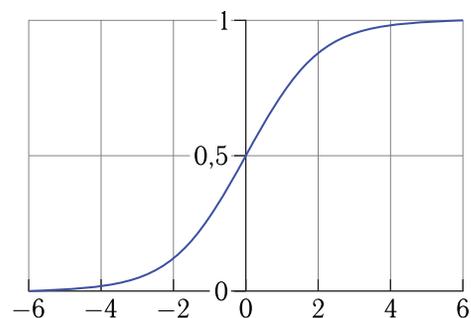


Рис. 7. Функция активации логистическая Sigmoid

роль классификатора, у которого количество выходных нейронов должно соответствовать количеству классов сигналов. Для текущей выборки количество выходных нейронов: 4.

Данные для обучения

Рассматриваются временные сигналы для следующих спутников:

- CosmoSkyMed,
- CSG,
- ICEYE,
- Santinel.

Отдельная выборка состоит из списка пар сигнал–класс сигнала.

Классом сигнала является тип спутника, к которому он принадлежит.

Сигнал представлен в виде двух массивов, один из которых состоит из действительной части сигнала, другой — из мнимой. Размерность каждого массива составляет 200 000 значений. В выборке присутствуют полностью зашумленные сигналы, со средним уровнем шума и сигналы без шума. Пример сигнала с шумом показан на рис. 8.

Выборка обучения [12] используется для формирования весовых коэффициентов нейронной сети, а валидационная — для прекращения обучения ней-

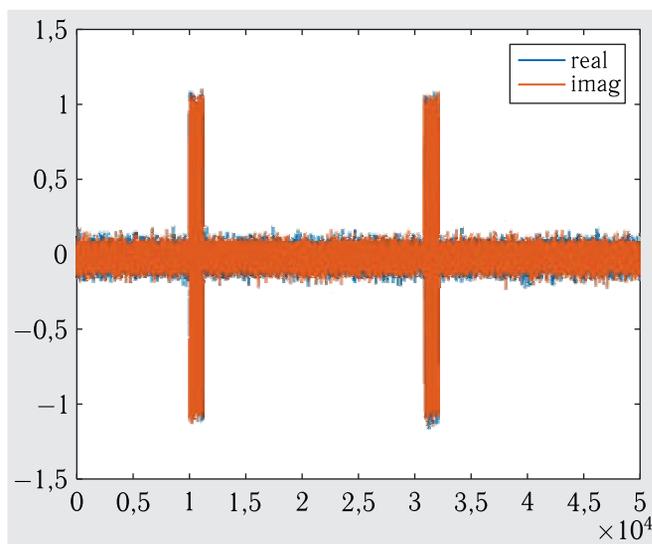


Рис. 8. Исходный зашумленный сигнал Santinel

ронной сети, когда ошибка на валидационной выборке начинает расти.

Размер выборок:

- обучение — 8000,
- валидация — 2000.

Показатели точности

В качестве метрики оценки классификатора используется точность [13]:

$$AC = \frac{1}{N} \text{MAX}_p \sum_{i=1 \dots K} n_{i,p(i)},$$

где n — количество правильно классифицированных объектов, N — количество объектов в выборке.

После обучения сверточной нейронной сети получены следующие показатели точности:

- тренировочный набор — 100%,
- тестовый (валидационный) — 99,4%.

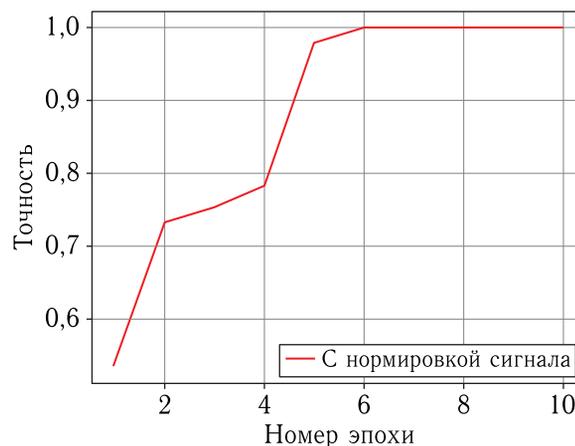


Рис. 9. Точность на тренировочном наборе

На рис. 9–12 показаны графики точности и потерь на тренировочном и валидационном наборах.

Обсуждение полученных результатов

Графики, представленные на рис. 9, 10, иллюстрируют динамику определения параметров нейронной сети в процессе ее обучения. Видно, что после выполнения шести эпох обучения полученные значения параметров обеспечивают точность

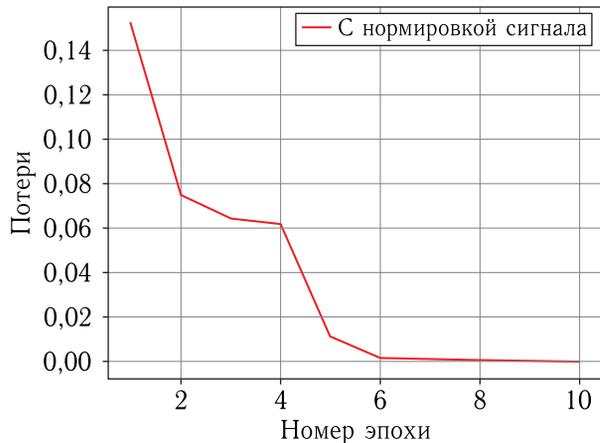


Рис. 10. Потери на тренировочном наборе

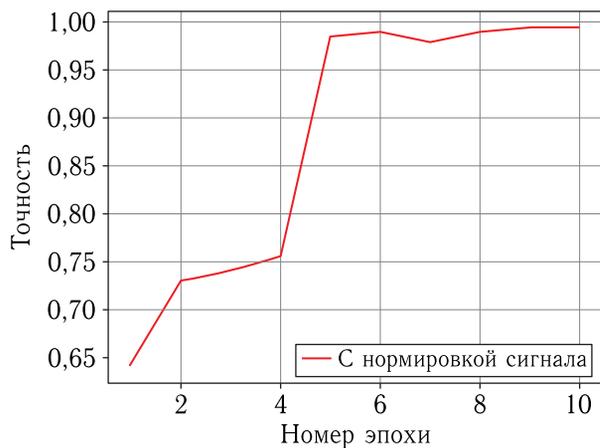


Рис. 11. Точность на валидационном наборе

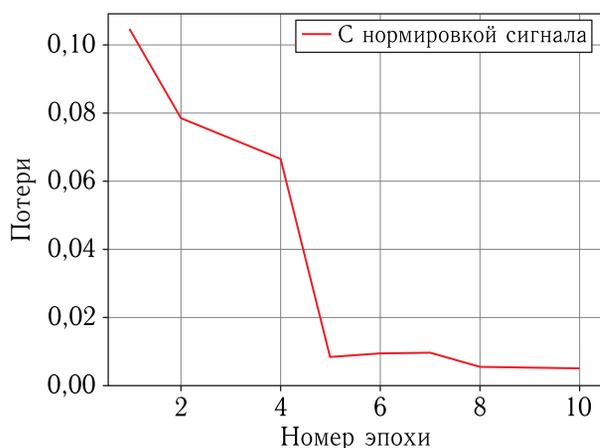


Рис. 12. Потери на валидационном наборе

классификации на тестовом наборе, равную 100%. Проведенные далее исследования на тестовом наборе (рис. 11, 12) показывают, что 6 эпох обучения

достаточно для окончательного определения значений характеристик нейронной сети. Высокая точность на тренировочном наборе свидетельствует о том, что модель обобщает образцы, представленные в данных обучения. Следует отметить, что в процессе обучения использовался обширный набор сигналов, полученных от различных космических аппаратов.

Высокая точность на тестовом наборе дает уверенность в надежности и качестве модели, показывает, что она действительно способна правильно классифицировать сигналы космических аппаратов, которых не было в обучающем наборе данных. Полученные результаты свидетельствуют о практической применимости разработанного метода.

Заключение

Радиотелескоп и программное обеспечение, разработанное на основе предполагаемого метода, могут работать в связке с системами контроля космического пространства в качестве вспомогательной системы. Разработанная система позволит определить класс сигнала для его дальнейшей обработки и получения информации.

Можно сделать предположения касательно преимуществ, недостатков и применимости предлагаемого метода. В частности, к преимуществам можно отнести: высокую скорость обнаружения и достаточно высокую точность, гибкость разрабатываемого программного обеспечения. К недостаткам можно отнести малое количество поддерживаемых в настоящее время спутников.

Разработанная система имеет перспективу дальнейшего развития. Возможны улучшения, связанные с расширением классов спутников. Также можно расширить функционал и дизайн пользовательского интерфейса.

Список литературы

1. Студеникин А.Г., Крыжко И.Б., Токарев А.Б., Ашихмин А.В., Фатеев А.А. Алгоритм предварительной идентификации радиосигналов по спектральным маскам // Системы управления, связи и безопасности, 2021, № 4. С. 15–22.

2. Пантенков Д. Г., Гусаков Н. В., Ломакин А. А. Методический подход к радиоконтролю сигналов спутниковой связи с оценкой требуемых энергетических характеристик приемных станций // Известия высших учебных заведений. Электроника, 2022, № 3. С. 385–389.
3. Иванюк В. А. Нейронные сети и их анализ // Хроноэкономика, 2021, № 4. С. 58–60.
4. Pierre Sermanet, Soumith Chintala, Yann LeCun. Convolutional Neural Networks Applied to House Numbers Digit Classification. arXiv:1204.3968v1 2012. P. 3–4.
5. Воронов И. В., Политов Е. А., Ефременко В. М. Обзор типов искусственных нейронных сетей и методов их обучения // Вестник Кузбасского государственного технического университета, 2007, № 3. С. 38–39.
6. Астапов Р. Л., Дубатов Р. С. Классификация текстов с помощью сверточных нейронных сетей // Вестник науки, 2020, № 8. С. 54–55.
7. Машнин А. В., Тимофеев А. В., Шаврин В. Ю. Метод линейной свертки // Инновационная наука, 2016, № 1. С. 39–40.
8. Зиатдинов С. И. Теорема отсчетов для комплексного и действительного сигналов // Известия высших учебных заведений. Приборостроение, 2012, № 1. С. 53–54.
9. Никулин В. Н., Канищев И. С., Багаев И. В. Методы балансировки и нормализации данных для улучшения качества классификации. // Компьютерные инструменты в образовании, 2016, № 3. С. 22
10. Hong-Ming Chiu, Richard Y. Zhang. Overcoming the Convex Relaxation Barrier for Neural Network Verification via Nonconvex Low-Rank Semidefinite. arXiv:2211.17244v1 2022. P. 2–3.
11. Yuan Xiao, Tongtong Bai, Mingzheng Gu, Chunrong Fang, Zhenyu Chen. Certifying Robustness of Convolutional Neural Networks with Tight Linear Approximation. rXiv:2211.09810v1 2022. P. 1–3.
12. Юнусова Л. Р., Магсумова А. Р. Алгоритмы обучения искусственных нейронных сетей // Наука, образование и культура, 2019. С. 1–5.
13. Pierre-Francois Marteau, Guiyao Ke. Exploiting a comparability mapping to improves bi-lingual data categorization: a three-mode data analysis perspective. arXiv:1502.07157v2 2015. 12 p.
14. Комплексное руководство по сверточным нейронным сетям. <https://datastart.ru/blog/read/kompleksnoe-rukovodstvo-po-svertochnym-neyronnym-setyam-dlya-chaynikov> (Дата обращения 02.05.2023.)
15. Andrey Svetozarov. Полносвязные слои нейронных сетей в машинном обучении. <https://habr.com/ru/articles/718044/> (Дата обращения 02.05.2023.)

Дата поступления рукописи
в редакцию 02.06.2023
Дата принятия рукописи
в печать 03.08.2023