

МИНОБРНАУКИ РОССИИ  
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ  
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ  
«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ  
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ  
ИМЕНИ Н.Г.ЧЕРНЫШЕВСКОГО»

Кафедра общей, теоретической и компьютерной физики

**КОМПЬЮТЕРНОЕ МОДЕЛИРОВАНИЕ НЕЙРОННЫХ СЕТЕЙ  
ДЛЯ РАСПОЗНАВАНИЯ РАДИОТЕХНИЧЕСКИХ СИГНАЛОВ**

**АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ**

студента 4 курса 4022 группы  
направления подготовки 03.03.02 «Физика» Института физики  
Попека Дмитрия Сергеевича

Научный руководитель  
доцент, к.ф.-м.н.

\_\_\_\_\_

подпись, дата

О.А. Черкасова

Заведующий кафедрой  
общей, теоретической и компьютерной физик  
д.ф.-м.н., профессор

\_\_\_\_\_

подпись, дата

В. М. Аникин

Саратов 2022 г.

## ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

**Актуальность работы.** Нейронная сеть способна выполнять многочисленные обработки информации за меньшее время, в отличие от человека. Пользуясь современными языками программирования и средствами обработки информации можно добиться хороших результатов в области машинного обучения. Дальнейшее развитие нейронных сетей позволяет исследовать проблему обработки информации с точки зрения физики и математики.

На сегодняшний момент для решения задач, связанных с большими вычислительными данными, применяют нейронные сети с различными методами обучения.

**Цель работы** – разработка программного нейросетевого алгоритма автоматизированной обработки радиотехнических сигналов на основе существующих парадигм искусственных нейронных сетей.

**Задачами** работы являются:

- 1) анализ состояния основных проблем, возникающих при распознавании и обработки сигналов;
- 2) сравнительная характеристика нейронных сетей, обоснование их места и роли при решении задач обработки сигналов. Классификация нейропроцессорных элементов и искусственных нейронных сетей;
- 3) разработка модели процесса идентификации сигналов на основе нейронной сети;
- 4) синтез нейронной сети для идентификации сигналов;
- 5) моделирование нейросетевого алгоритма для обработки сигналов.

Исследования проводились с помощью численного моделирования с использованием программных пакетов Matlab, C и C++.

**Объект исследования** – нейронная сеть, обученная с помощью сигмоидной функцией.

К числу *новых (защищаемых) результатов* отнести разработку численного и программного моделирования работы нейронной сети.

**Достоверность результатов** подтверждается разработкой и результатом программы для моделирования работы нейронной сети.

**Теоретическая значимость** работы связана с выявлением особенностей свойств нейронных систем, демонстрирующих возможность избавления сигнала от шума.

**Практическая значимость** работы обусловлена демонстрацией прикладных возможностей физики и математического анализа, для демонстрации модели нейронной сети.

**Структура ВКР.** Выпускная квалификационная работа (ВКР) содержит введение, 4 главы, заключение, список использованных источников (32 наименования).

## ОСНОВНОЕ СОДЕРЖАНИЕ РАБОТЫ

**Во введении** приводятся аспектные характеристики работы (актуальность, цель и задачи работы, особенность подхода).

**В первой**, обзорной по характеру главе, излагается базовая модель, о сборе данных для нейронной сети, а также теория нейронной сети.

**Во второй** главе рассматривались основные принципы оценивания и зависимость между переменными.

**В третьей** главе говорится об обучающих данных, алгоритмах и методах обучения.

**В четвертой** главе строится сигнал, который хотим сохранить, искаженный шумом сигнал и демонстрируется, как нейронная сеть смогла отфильтровать сигнал.

Графически модель нейрона можно представить в виде нескольких связей, как показано на рисунке 1. Как видно из рис. 1, на вход нейрона поступают сигналы  $x_i$ , каждый из которых умножается на вес  $w$  (для каждого сигнала имеется собственный вес), затем производится сложение преобразованных сигналов и добавляется порог, после чего результат преобразуется с помощью функции активации  $f$  и подается на выход нейрона.

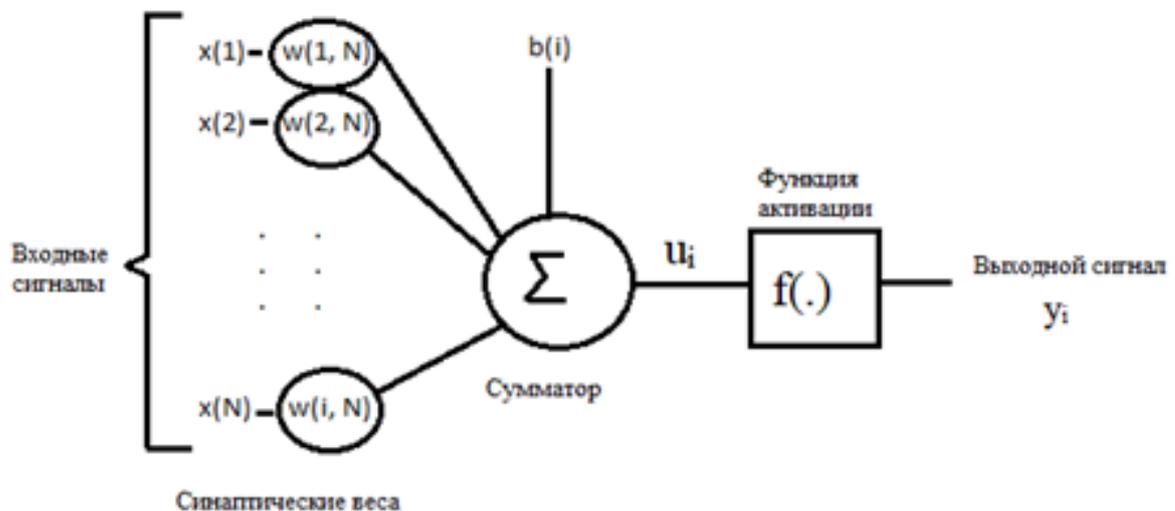


Рисунок 1 – Модель нейрона

В модели нейрона вес моделирует силу синапса. Таким образом, при создании модели нейронной сети необходимо учитывать следующие положения:

- нейрон получает сигналы через несколько входных каналов, они показаны на схеме слева (рис. 1);
- каждый сигнал проходит через соединение - синапс, имеющее определенную силу или вес  $w(i,j)$ , который соответствует синаптической активности нейрона; коэффициенты  $w(i,j)$  называются весами синаптических связей, положительные значения которых

соответствуют возбуждающим синапсам, отрицательные значения — тормозящим синапсам; если  $w(i,j) = 0$ , то говорят, что связь между нейроном  $i$  и нейроном  $j$  отсутствует;

- текущее состояние нейрона описывается формулой:

$$u_i = \sum_{j=1}^N w(i,j)x(j) + b(i), \quad (1)$$

где  $x(j)$ ,  $j = 1, 2, \dots, N$  - входные сигналы;  
 $b(i)$  – пороговые значения (порог активации);

- полученный нейроном сигнал преобразуется с помощью нелинейной функции активации или передаточной функции  $f$  в выходной сигнал

$$y_i = f(u_i). \quad (2)$$

Рассмотрим функции активации нейронов, которая представляет собой нелинейную функцию, моделирующую процесс передачи возбуждения. Для описания функции активации используются следующие основные типы:

1. Пороговая функция или функция единичного скачка, определяемая равенствами:

$$f(u) = 1, \text{ если } u \geq 0, f(u) = 0, \text{ если } u < 0. \quad (4)$$

2. Сигмоидальная функция - это функция  $f$  вида

$$f(u) = \frac{1}{1 + e^{-bu}}, \text{ где } b > 0. \quad (5)$$

3. Кусочно-линейная функция:

4.

$$f(u) = 1, \text{ если } u > 0,5, f(u) = |u|, \text{ если } |u| < 0,5, f(u) = 0, \text{ если } u < -0,5.$$

5. Функция знак (сигнум):

$$f(u) = -1, \text{ если } u < 0, f(u) = 1, \text{ если } u \geq 0.$$

Входной слой нейронов служит для ввода значений входных переменных, выходной слой — для вывода результатов. Последовательность слоев нейронов и их соединений называется архитектурой сети. Задать сеть - это задать ее архитектуру и параметры нейронов.

Для проверки нормальности применяются визуальные методы, например, гистограммы, нормальные вероятностные графики или численные методы с помощью оценки коэффициентов асимметрии и эксцесса; используется также критерий хи-квадрат.

Цифровая фильтрация — это широко используемый метод, распространенный во многих областях науки и техники. Фильтры удаляют нежелательные сигналы и шумы из полезного сигнала.

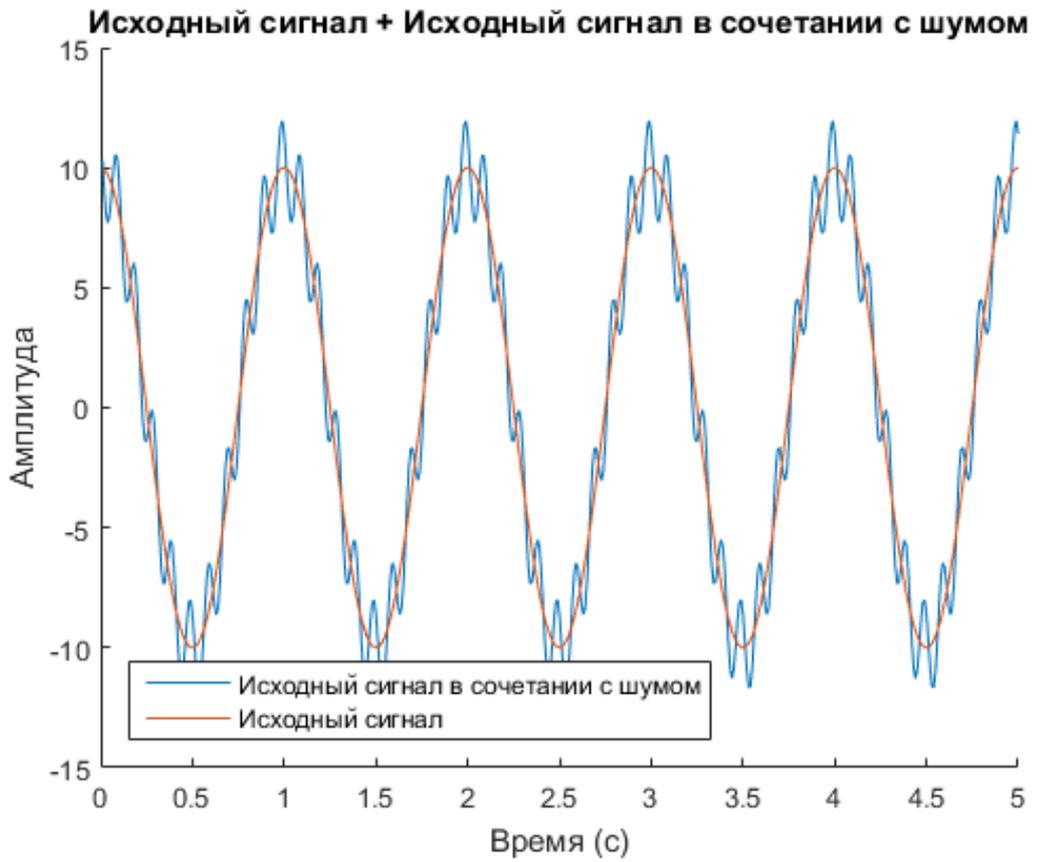


Рисунок 2 – Сравнение сигналов

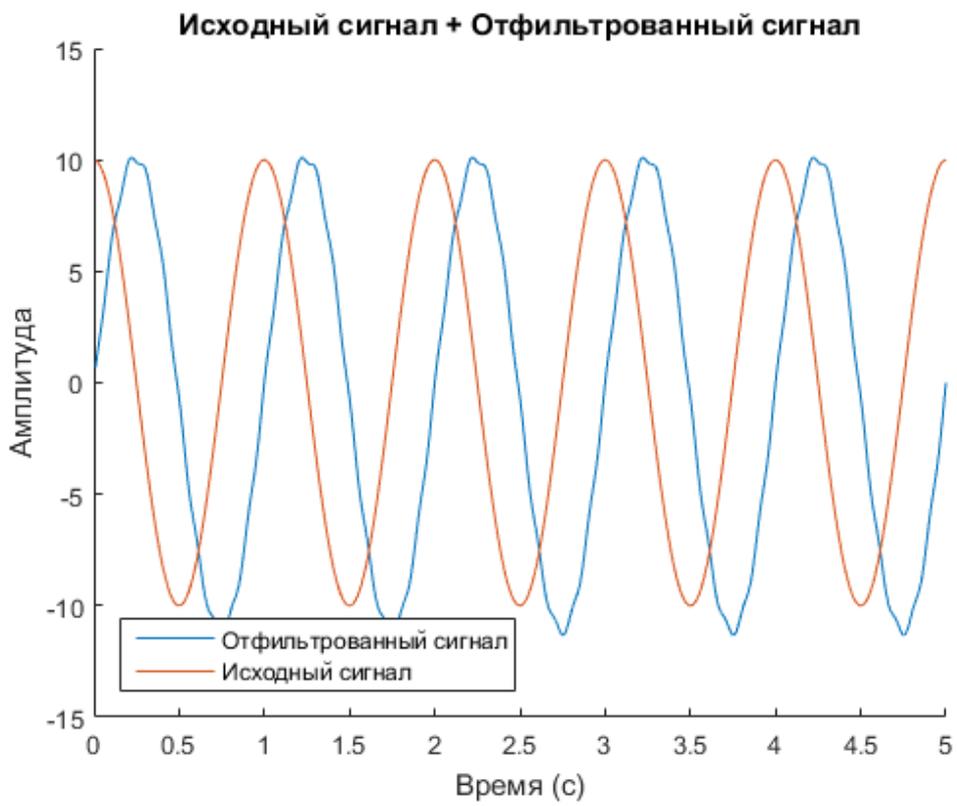


Рисунок 3 - Результат программы

## ЗАКЛЮЧЕНИЕ

Не смотря на бурный рост популярности нейронных сетей, некоторые области их использования до сих пор слабо изучены, также существуют проблемы в виде дефицита размеченных данных для обучения сети. Автоматическая классификация звуков окружающей среды событий может быть полезна в поиске информации, имея приложения для мультимедиа контент-анализа, контекстно-зависимые устройства и устройства аудио-наблюдения и мониторинга. Также эффективная классификация звуков среды может помочь решить проблему фильтрации посторонних шумов при обработке сигнала, несущего информацию.

На основании вышеизложенного можно сделать следующие выводы:

1. Изучены механизмы создания нейронных сетей для распознавания и обработки сигналов.
2. Разработана модель нейросетевого алгоритм с глубоким обучением для идентификации радиосигналов.
3. Проведен вычислительный эксперимент, подтверждающий высокую эффективность разработанной модели.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Рашид, Тарик. Создаем нейронную сеть, М. : Вильямс, 2019. 272 с.
2. Нейронные сети. STATISTIKA Neural Networks: Методология и технология современного анализа данных / Под редакцией В.П. Боровикова. 2-е изд., перераб. и доп. М.: Горячая линия – Телеком, 2008.-392 с.
3. Гафаров Ф.М. Искусственные нейронные сети и приложения: учеб. пособие / Ф.М. Гафаров, А.Ф. Галимянов. Казань: Изд-во Казан. ун-та, 2018. 121 с.
4. Слепенков В. О. Использование технологий машинного обучения для создания искусственных нейронных сетей / В. О. Слепенков, А. В. Бондарь // Молодежный научно-технический вестник. 2016. № 4. С. 20.
5. Переверзев И. А. Эффективные алгоритмы построения нейронной сети на основании оценки входных параметров (глубокое машинное обучение) / И. А. Переверзев, В. Н. Квасницкий // Вестник Московского финансово-юридического университета. 2016. № 1. С. 253-261.
6. Мамхягов А. З. Нейронные сети: машинное обучение, искусственный интеллект - зачем нам думать // Молодежь и наука: реальность и будущее: Материалы X межд. научно-практ. конф., Невинномысск, 01 марта 2017 года / Редколлегия: Т.Н. Рябченко, Е.И. Бурьянова. Невинномысск: НОУ ВПО "Невинномысский институт экономики, управления и права", 2017. – С. 93-96.
7. Тихонов А. А. Большие данные и глубокое машинное обучение в искусственных нейронных сетях // Наука и образование сегодня. 2018. № 6(29). С. 35-38.
8. Gencoglu Oguzhan, Virtanen Tuomas, Huttunen Heikki. Recognition of acoustic events using deep neural networks. URL: <https://www.eurasip.org/Proceedings/Eusipco/Eusipco2014/HTML/papers/1569924623.pdf> . Дата обращения: 13.02.2022.

9. Zheng S., Jayasumana S., Romera-Paredes B., Vineet V., Su Z., Du D., Huang C., Torr P. H. S., Conditional Random Fields as Recurrent Neural Networks // Proceedings of the 2015 IEEE International Conference on Computer Vision. – 2015. P. 1529–1537.
10. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition // IEEE Conference on Computer Vision and Pattern Recognition. 2016. P. 770–778.
11. Rashchenko Y. V., Kozynchenko V. A. New algorithms of an artificial neural network ART-1 training // IEEE 2015 International Conference «Stability and Control Processes» in memory of V. I. Zubov (SCP). 2015. P. 663–664.
12. Глубокое обучение для новичков: распознаем изображения с помощью сверточных сетей. URL: <https://habrahabr.ru/company/wunderfund/blog/314872/> (Дата обращения: 03.02.2022).
13. Nicolaos B. Karayiannis and Mary M. Randolph-Gips. On the Construction and Training of Reformulated Radial Basis Function Neural Networks // IEEE Trans of Neural Network. 2003. Vol.14. P. 835–846.
14. Розенблат Ф. Принципы нейродинамики. Перцептроны и теория механизмов мозга. М.: Мир, 1965. 481 с.
15. Манжула В.Г., Федяшов Д.С. Нейронные сети кохонена и нечеткие нейронные сети в интеллектуальном анализе данных // Фундаментальные исследования. 2011. № 4. С. 108-115.
16. Белоглазов Д. А. Особенности нейросетевых решений, достоинства и недостатки, перспективы применения // Известия ЮФУ. Технические науки. 2008. №7. С. 105-110.
17. Chapman N. R., Cornish J. W. Wind dependence of deep ocean ambient noise at low frequencies. J. Acoust. Soc. Am., 1993, 93(2), 782–789.
18. Hinton G.E., Nowban S.J. How Learning Can Guide Evolution // Complex systems. 1987. N 1. P. 495–512.
19. Кутыркин А.В., Сёмин А.В. Использование нейронной сети Хопфилда для решения оптимизационных задач маршрутизации: Методические указания. М.: МИИТ, 2007. 15 с.
20. Павлова А. И., Бобкова К. А. Сравнение алгоритмов распознавания образов нейронными сетями хопфилда // В мире научных открытий. 2016. №5 (77). С. 134-145. DOI: 10.12731/wsd-2016-5-7.
21. Любатов Ю.В. Теоретические основы моделирования цифровых систем. М.: МАИ, 1989. 77 с.
22. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. М.: Финансы и статистика, 2002. 344 с.
23. Загрудинов Г. М. Достоверность автоматизированного контроля. Казань: Изд-во Казанского университета, 1980. 280 с.
24. Wilson J. H. Very Low Frequency Wind-Generated Noise Produced by Turbulent Pressure Fluctuations in the Atmosphere near the Ocean Surface // J. Acoust. Soc. Am.. 1979. Vol. 65, no. 5. P. 1499–1507.
25. Hopfield J.J. The Effectiveness of Analogue Neural Network.Hardware // Networks. 1990. N 1. P. 27–40.
26. Меркушева А.В. Применение нейронной сети для текущего анализа нестационарного сигнала (речи), представленного его вейвлет-отображением. II. исследование и оптимизация нейронной сети / А. В. Меркушева // Научное приборостроение. 2003. Т. 13. № 1. С. 72-84.
27. Hannun, A., et al. Deep Speech 2: End-to-End Speech Recognition in English and Mandarin. URL: <https://proceedings.mlr.press/v48/> (Дата обращения: 02.02.2022).
28. Hinton, G. E., et al. A Fast Learning Algorithm for Deep Belief Nets // Neural Computation. 2006. Vol. 18. P. 1527-1554.
29. Jia, Y., et al. Caffe: Convolutional Architecture for Fast Feature Embedding, 2014. URL : <https://ucb-icsi-vision-group.github.io/caffe-paper> (Дата обращения: 05.02.2022)

30. Le, Q.V, et al. Building High-Level Features Using Large Scale Unsupervised Learning // Proceedings of the 29th International Conference on Machine Learning, Edinburgh, 2012. URL: <https://icml.cc/2012/papers> (Дата обращения 05.02.2022).
31. Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain // Psychological Review. 1958. Vol. 65. No. 6. P.386–408. <https://doi.org/10.1037/h0042519>
32. Russakovsky, O., et al., “ImageNet Large Scale Visual Recognition Challenge”, 2015, [Сайт] URL: <https://www.bibsonomy.org/bibtex> (Дата обращения: 13.02.2022)