

Е.Т. Кожажулов<sup>1</sup>, Д.М. Жексебай<sup>1</sup>, А.Т. Намазбаев<sup>1</sup>, С.А. Сарманбетов<sup>1\*</sup>

<sup>1</sup>Казахский национальный университет имени аль-Фараби, г. Алматы, Казахстан  
\*e-mail: sarmanbetov.sanzhar@gmail.com

## ЭФФЕКТИВНАЯ КЛАССИФИКАЦИЯ ЦИФРОВОЙ МОДУЛЯЦИИ С ИСПОЛЬЗОВАНИЕМ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

### Аннотация

Работа направлена на улучшение эффективности идентификации различных типов цифровой модуляции. Она включает в себя анализ текущих методик автоматического определения модуляций, выявление и классификацию особенностей цифровой модуляции, а также создание уникальной базы данных для этих целей. В исследовании предложен современный подход, основанный на технологии глубокого обучения с применением сверточных нейронных сетей, обучающихся на специально подготовленном наборе данных, что позволяет значительно повысить точность классификации. Установлена связь между сверточным нейронным сетем (CNN) и сигналом модуляции, где сверточная нейронная сеть обучается на синфазных и квадратурных выборках сигналов. Подобранные параметры сети обеспечивают более высокую точность измерения. Эксперименты показали, что сверточная нейронная сеть способна классифицировать сигналы с высоким уровнем даже при низком отношении сигнала/шума (SNR), превышающем 99,9%, за исключением квадратурной фазовой манипуляции (QPSK) (94,5%). Полученные результаты демонстрируют эффективность использования глубокого обучения для приборов цифровой модуляции.

**Ключевые слова:** классификация модуляции, сверточные нейронные сети, отношение сигнал/шум, множественная фазовая модуляция (MPSK), автоматическая классификация модуляции.

Е.Т. Кожажулов<sup>1</sup>, Д.М. Жексебай<sup>1</sup>, А.Т. Намазбаев<sup>1</sup>, С.А. Сарманбетов<sup>1</sup>

<sup>1</sup>әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

## ҚҮЙРКІЛІ НЕЙРЛІК ЖЕЛІЛЕРДІ ПАЙДАЛАНАТЫН ЦИФРЛЫҚ МОДУЛЯЦИЯНЫҢ ТИІМДІ ЖІКТЕЛУІ

### Аңдатпа

Бұл жұмыс сандық модуляцияның әртүрлі түрлерінің сәйкестендіру өнімділігін жақсартуға бағытталған. Ол модуляцияны автоматты түрде анықтаудың ағымдағы әдістерін талдауды, сандық модуляция мүмкіндіктерін анықтауды және жіктеуді және осы мақсаттар үшін бірегей деректер қорын құруды қамтиды. Зерттеу арнайы дайындалған деректер жиынында оқытылатын конволюционды нейрондық желілерді қолданатын терең оқыту технологиясына негізделген заманауи тәсілді ұсынады, бұл жіктеу дәлдігін айтарлықтай жақсарты алады. Үйірткілі нейрондық желі және модуляция сигналы арасында байланыс орнатылады, мұнда үйірткілі нейрондық желі фазалық және квадраттық сигнал үлгілерінде оқытылады. Таңдалған желі параметрлері жоғары өлшеу дәлдігін қамтамасыз етеді. Тәжірибелер үйірткілі нейрондық желі жоғары деңгейлі сигналдарды төмен сигнал-шу қатынасы 99,9%-дан асатын болса да, төртбұрышты фазалық ығысу кілті (94,5%) қоспағанда жіктей алатынын көрсетті. Алынған нәтижелер сандық модуляция құрылғылары үшін терең оқытуды қолданудың тиімділігін көрсетеді.

**Түйін сөздер:** модуляция классификациясы, үйірткілі нейрондық, сигнал-шуыл қатынасы, нейрондық желілер, көп фазалы модуляция, автоматты модуляция классификациясы.

Y.T. Kozhagulov<sup>1</sup>, D.M. Zhexebay<sup>1</sup>, T.A. Namazbayev<sup>1</sup>, S.A. Sarmanbetov<sup>1</sup>  
<sup>1</sup>al-Farabi Kazakh National University, Almaty, Kazakhstan

## EFFECTIVE CLASSIFICATION OF DIGITAL MODULATION USING CONVOLUTIONAL NEURAL NETWORKS

### *Abstract*

This work aims to improve the identification performance of different types of digital modulation. It includes an analysis of current techniques for automatic modulation detection, identification and classification of digital modulation features, and the creation of a unique database for these purposes. The study proposes a modern approach based on deep learning technology using convolutional neural networks (CNN) trained on a specially prepared data set, which can significantly improve classification accuracy. A connection is established between the CNN and the modulation signal, where the CNN is trained on in-phase and quadrature signal samples. Selected network parameters provide higher measurement accuracy. Experiments have shown that CNN is able to classify high-level signals even with low signal-to-noise ratio (SNR) exceeding 99.9%, with the exception of QPSK (94.5%). The results obtained demonstrate the effectiveness of using deep learning for digital modulation devices.

**Keywords:** modulation classification, convolutional neural networks, signal-to-noise ratio, neural networks, Multi Pre-Shared Key, Automatic Modulation Classification.

### **Основные положения**

В исследовании предлагается метод улучшения точности распознавания типов цифровой модуляции с использованием сверточных нейронных сетей (CNN), что позволяет достигать точности классификации выше 99,9% для большинства видов модуляции при различных значениях соотношения сигнал/шум. Разработана и применена уникальная база данных для обучения нейронной сети, включающая 9600 модулированных сигналов, собранных с использованием специализированного оборудования NI, что стало ключевым фактором успешного обучения модели.

Архитектура предложенной CNN состоит из четырех сверточных слоев и двух плотных слоев с активационной функцией ReLU, что обеспечивает высокую производительность и точность модели. Экспериментальные результаты показывают, что предложенная модель CNN сохраняет высокую точность распознавания даже при низком уровне сигнал/шум, особенно для видов модуляции двоичная фазовая манипуляция (Binary Phase Shift Keying (BPSK)), восьмипозиционная фазовая модуляция (8 Phase-Shift Keying (8PSK)), шестнадцати позиционная фазовая модуляция (16 Phase-Shift Keying (16PSK)), тридцати двух позиционная фазовая модуляция (32 Phase-Shift Keying (32PSK)) и шестидесяти четырех позиционная фазовая модуляция (64 Phase-Shift Keying (64PSK)), достигая точности выше 99,9%.

Предложенная модель CNN демонстрирует значительное улучшение производительности по сравнению с существующими методами, подчеркивая потенциал глубокого обучения в задачах распознавания модуляции и предлагая перспективы для практического применения в сфере цифровой связи. Дальнейшие исследования будут направлены на усовершенствование сетевой архитектуры и методы обобщения модели для различных условий и наборов данных, что обеспечит эффективное развертывание моделей в реальных условиях эксплуатации.

### **Введение**

В контексте телекоммуникационных систем, одной из ключевых проблем является идентификация типов цифровой модуляции, что находит свое применение в областях радиомониторинга и радиоконтроля, среди прочего. Идентификация типов цифровой модуляции оказывает существенное влияние на эффективность телекоммуникационных систем. Во-первых, умение определять тип цифровой модуляции позволяет непосредственно идентифицировать источник передачи сигнала. Во-вторых, успешное декодирование, последующее за определением типа модуляции, ведет к возможности восстановления передаваемого сообщения. В-третьих, точное распознавание модуляций необходимо для

функционирования систем активного радиопомех, цель которых - нарушение сигнального взаимодействия между устройствами. Автоматическая классификация модуляции вслепую определяет схему модуляции системы в условиях неизвестной априорной информации. Такой как информация о состоянии канала и параметры передающего оборудования системы.

Однако существующие методы, основанные на глубоком обучении, напрямую получают характеристики исходного сигнала для идентификации метода модуляции. Из-за разной силы шума в модулированных сигналах с разным отношением сигнал/шум существующие модели могут использовать только глубокие нейронные сети для извлечения убедительных признаков в сигналах для повышения точности распознавания. Однако это часто приводит к сложному балансу между сложностью модели и точностью распознавания. Шум в сигнале является основной причиной необычайно сложной структуры существующих моделей с высокой скоростью распознавания. Поэтому крайне важно разработать эффективную сеть классификации модуляции, которая может адаптивно очищать входные сигналы от шума при различных отношениях сигнал/шум.

#### *Обзор литературы и постановка проблемы.*

В современной научной и технической литературе описаны различные методологии для автоматизированного определения типов модуляции, включая анализ формы сигнального созвездия, использование пороговых значений и применение искусственных нейронных сетей. В исследованиях [1-3] представлен метод построения сигнального созвездия и последующее сравнение мгновенной угловой фазы и конфигурации созвездия. Основная проблематика данного подхода заключается в реконструкции сигнального созвездия с применением алгоритмов, базирующихся на методе fuzzy c-means, как обсуждается в [4].

Исследование [5-6] фокусируется на алгоритме восстановления сигнального созвездия через fuzzy c-means, обеспечивающем эффективную нечеткую кластеризацию больших данных. Этот метод демонстрирует преимущества при сближенных классах и наличии значительного количества точек на их периферии, показывая до 90% точности при отношении сигнал/шум в 5dB и анализе многопозиционной фазовой манипуляции (MPSK) модуляции.

В исследованиях [7-9] рассмотрена методика, предполагающая вычисление информационных признаков из исходных данных и их последующее сравнение с заданными порогами, определяемыми экспериментально. Этот процесс, воплощенный в форме дерева решений, был изучен на примере фазовой манипуляции (phase-shift keying (PSK)) и цифровой квадратурной модуляции (QAM) сигналов при различных уровнях SNR (0, 8, 50, 100 dB). С недавних пор, благодаря своей высокой эффективности в задачах распознавания образов, искусственные нейронные сети начали активно применяться во множестве современных систем, включая автоматическое распознавание типов цифровой модуляции, как это подтверждается в работах [10-13]. Предложенные методы в [10-13] могут различать типы цифровой модуляции более высокого порядка, таких как 256QAM и 1024QAM.

В [14] предложили использовать сверточные нейронные сети (CNN) для различения различных типов модулированных сигналов. Результаты показали, что производительность моделей CNN была значительно лучше, чем у методов, основанных на признаках. В этой статье генерируются 11 общих сигналов цифровой модуляции для обработки классификации модуляции. Типы этих сигналов: BPSK, QPSK, 2FSK, 4FSK, 8FSK, Амплитудно-фазовая 2 Amplitude-shift keying (2ASK), 4ASK, 8ASK, 16QAM, 32QAM, 64QAM. Диапазон SNR составляет от -2 до 10 dB с шагом 2 dB. Точность классификации сигналов составляет 82,8182%. В публикации [15] представлены модели автоматического распознавания высокой точности, использующие глубокие архитектуры, включая сверточные глубокие нейронные сети с долгосрочной и краткосрочной памятью (CLDNN) и глубокие остаточные нейронные сети (ResNet).

В [16] было использовано кратковременное преобразование Фурье (STFT) для преобразования временных рядов в спектральные изображения в качестве входных данных

сети CNN и достигнута хорошая точность классификации. В последнее время некоторые ученые использовали методы глубокого обучения для проведения предварительных исследований текущих проблем в области распознавания модуляции. Например, исследование метода идентификации сигнала модуляции образцов с нулевой меткой в конкретных сценариях [15], обнаружение сигнала и автоматическая классификация модуляции в безопасном динамическом доступе к спектру [17]. В работе [17] была достигнута повышенная точность распознавания.

*Цель и задачи исследования*

Основная цель данного исследования заключается в идентификации и разработке методов для улучшения точности идентификации типов цифровой модуляции. Для достижения этой цели, исследование сосредоточено на выполнении следующих задач:

1. Изучение и анализ текущих методик в области автоматического определения видов цифровой модуляции.
2. Исследование, анализ и классификация характеристик для автоматического определения таких типов цифровой модуляции, как BPSK, QPSK, 8-PSK, 16PSK, 32PSK и 64PSK.
3. Сбор собственной базы данных.

**Методология исследования**

*Материалы и методы*

В работе предлагается сеть CNN.

Структура CNN показана на рисунке 1 и в таблице 1.

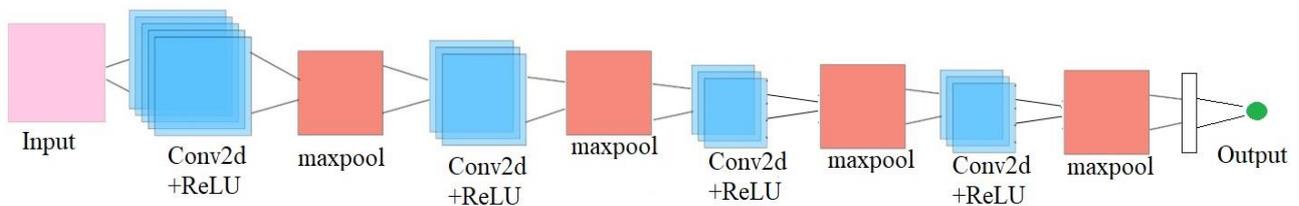


Рисунок 1. Структура сети

Таблица 1. Параметры сети

Layer (type)	Output Shape	Param
conv2d (Conv2D)	(None, 2, 1024, 256)	1792
max_pooling2d (MaxPooling2D)	(None, 2, 512, 256)	0
conv2d_1 (Conv2D)	(None, 2, 512, 128)	196736
max_pooling2d_1	(MaxPooling2 (None, 2, 256,	0
conv2d_2 (Conv2D)	(None, 2, 256, 64)	49216
max_pooling2d_2	(MaxPooling2 (None, 2, 128, 64)	0
conv2d_3 (Conv2D)	(None, 2, 128, 64)	24640
max_pooling2d_3	(MaxPooling2 (None, 2, 64, 64)	0
flatten (Flatten)	(None, 8192)	0
dense (Dense)	(None, 128)	1048704
dense_1 (Dense)	(None, 6)	774
Total params	1,321,862	
Trainable params	1,321,862	
Non-trainable params	0	

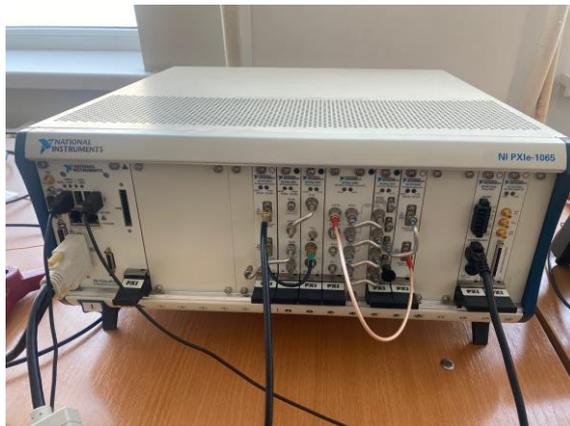
В этой статье модель CNN построена с использованием Keras ,библиотека для языка программирования Python (Tensorflow). Предлагаемая модель CNN включает в себя четыре слоя свертки и объединения (pooling layer), заканчивающихся двумя плотными слоями. Использовано функция активации ReLU.

Для оптимальной производительности использовали 256 фильтров на первом уровне, а на последнем уровне было 64 фильтра. Первый плотный слой образован 128 нейронами и функцией активации ReLU.

В процессе обучения мы используем 20 интерации. На этапах обучения и тестирования использовали Intel(R) Core-I7-8700 CPU, 3,2 GHz, ОЗУ 16 Gb, NVIDIA GeForce GTX 1080. С помощью библиотеки Tensorflow GPU было сделано параллельное вычисление на основе технологии CUDA (v 9.2).

### **Результаты исследования**

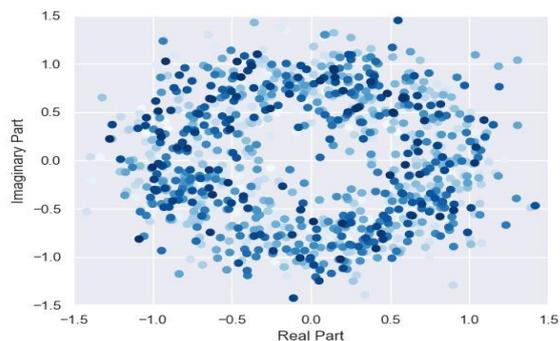
Для обучения используются собственная база данных для входа CNN. Сбор видов цифровой модуляции выполнено через инструмент NI PXIe-1065 с прием-передатчиком (RF Signal Generator NI PXI-5652, RF Downconverter NI PXIe-5601, 16-Bit IF Digitizer NI PXIe-5622, I/Q Signal Generator NI PXIe-5450, I/Q Vector Modulator NI PXIe-5611). Оборудование для сбора базы данных показано на рисунке 2.



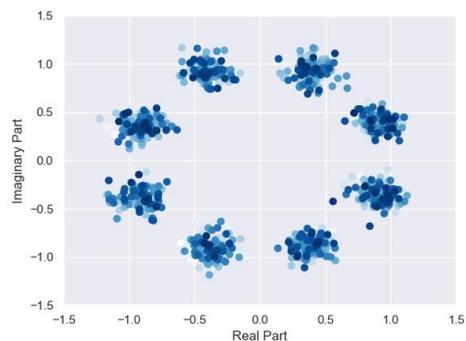
*Рисунок 2. Оборудование NI PXIe-1065 для сбора базы данных*

Для создания необходимой для тренировки нейронных сетей базы данных различных модуляций было произведено генерирование 9600 информационных сигналов с продолжительностью в 1024 отсчета каждый. Эти сигналы, передаваемые через канал связи, подверглись воздействию шумов, следующих нормальному распределению, при этом соотношение сигнал/шум (С/Ш) варьировалось в пределах от 0 до 15 дБ для целых значений С/Ш, выбираемых случайным образом. Для преобразования полученных высокочастотных сигналов в IQ данные использовались стандартные процедуры оборудования NI. В результате, набор данных для обучения был организован в виде матрицы с размерами 6x16x100x1024, где каждый элемент представляет собой определенный тип цифровой модуляции, при этом конкретное значение элемента установлено равным единице. Где 6 это виды модуляции (BPSK, QPSK, 8PSK, 16PSK, 32PSK, 64PSK), 16-значения ОСШ (0-15), 100- количество записей в одной модуляции с одним значением ОСШ. Алгоритм обучения - метод обратного распространения ошибки.

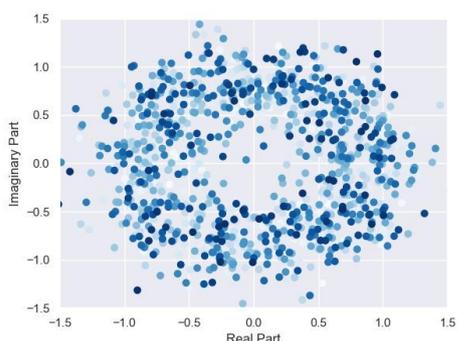
Чтобы проверить обученную сеть, используем проверочный набор (рис. 3), на котором представлена точность распознавания сети при 4 режимах модуляции при различных SNR (рис. 4).



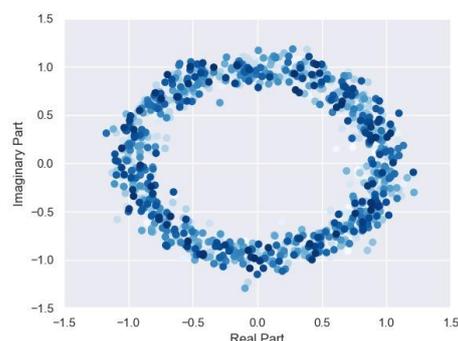
(a) 8PSK 7dB



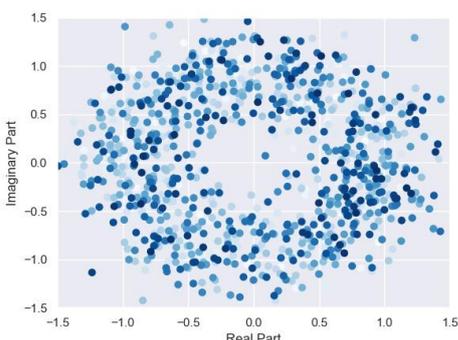
(б) 8 PSK 15dB



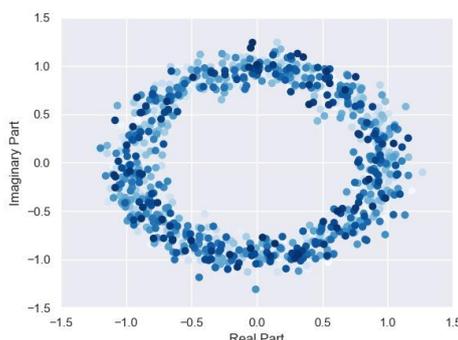
(в) 16 PSK 7dB



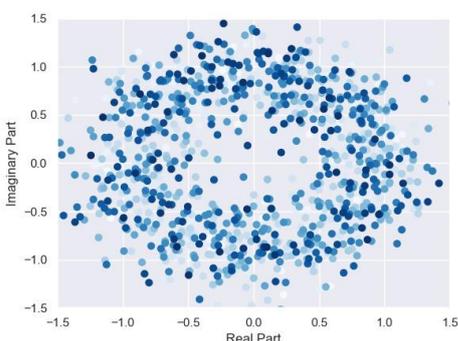
(г) 16 PSK 15 dB



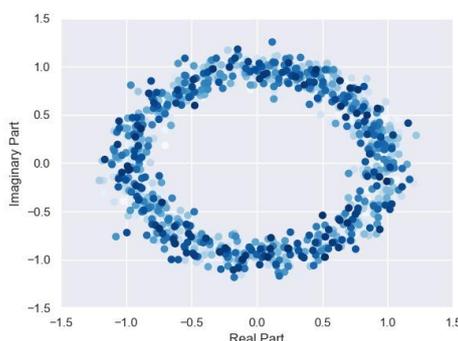
(д) 32 PSK 7 dB



(е) 32 PSK 15 dB



(ж) 64 PSK 7dB



(з) 64 PSK 15dB

Рисунок 3. Созвездия MPSK с SNR 7 и 15 dB (а-8PSK 7dB, б-8PSK 15dB, в-16PSK 7dB, г-16PSK 15dB, д-32PSK 7dB, е-32PSK 15dB, ж-64PSK 7dB, з-64PSK 15dB)

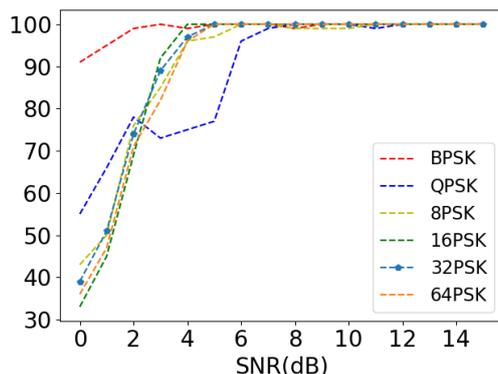
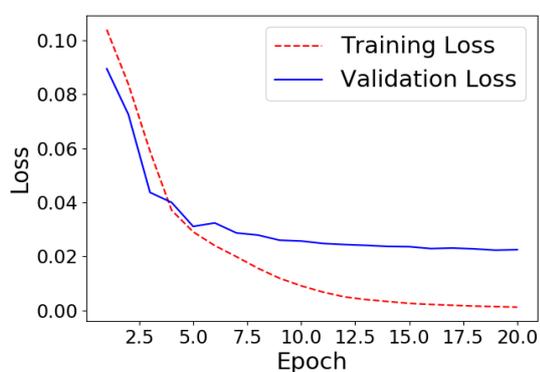
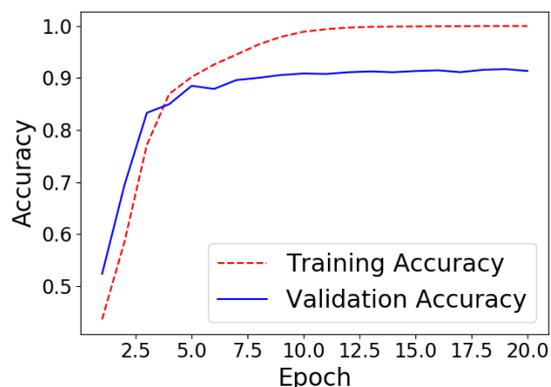


Рисунок 4. Точность распознавания модуляции

Точность и потери на этапе обучения используются для оценки эффективности обучения моделей. Наша модель завершила обучение менее чем за 20 эпох. Точность и потери на этапе обучения можно увидеть на рис. 5(a) и рис. 5(b) соответственно.



(a) Точность обучения



(б) Потеря обучения

Рисунок 5. Сравнение эффективности обучения (а-Точность обучения, б- Потеря обучения)

## Дискуссия

### Обсуждение результатов эксперимента

Когда SNR составляет 6 dB, большинство сигналов достигают уровня точности, превышающего 99,9%, за исключением QPSK (94,5%). С увеличением SNR точность распознавания возрастает. Для дальнейшего анализа производительности нашей сети по распознаванию сигналов модуляции мы изучаем матрицы путаницы сигналов при различных SNR, т. е. низкое SNR при 0 dB и высокое при 15 dB. Соответствующие матрицы представлены на рис. 6. Из рисунка можно сделать вывод, что большинство ошибок сосредоточено в одинаковых режимах модуляции. Учитывая случай 6 dB, наш метод обеспечивает общую точность 99,9%. В частности, для QPSK (94,5%), BPSK, 8PSK, 16PSK, 32PSK, 64PSK (99,9%).

## Заключение

В статье подробно рассмотрено использование сверточных нейронных сетей (CNN) для улучшения точности распознавания различных видов цифровой модуляции, подчеркивая значимость собственной базы данных, сформированной при помощи специализированного оборудования ИИ для обучения этих сетей. Процесс сбора данных включал генерацию огромного количества модулированных сигналов и их последующую обработку с целью создания обширного и многообразного датасета, что стало ключом к успешному обучению модели.

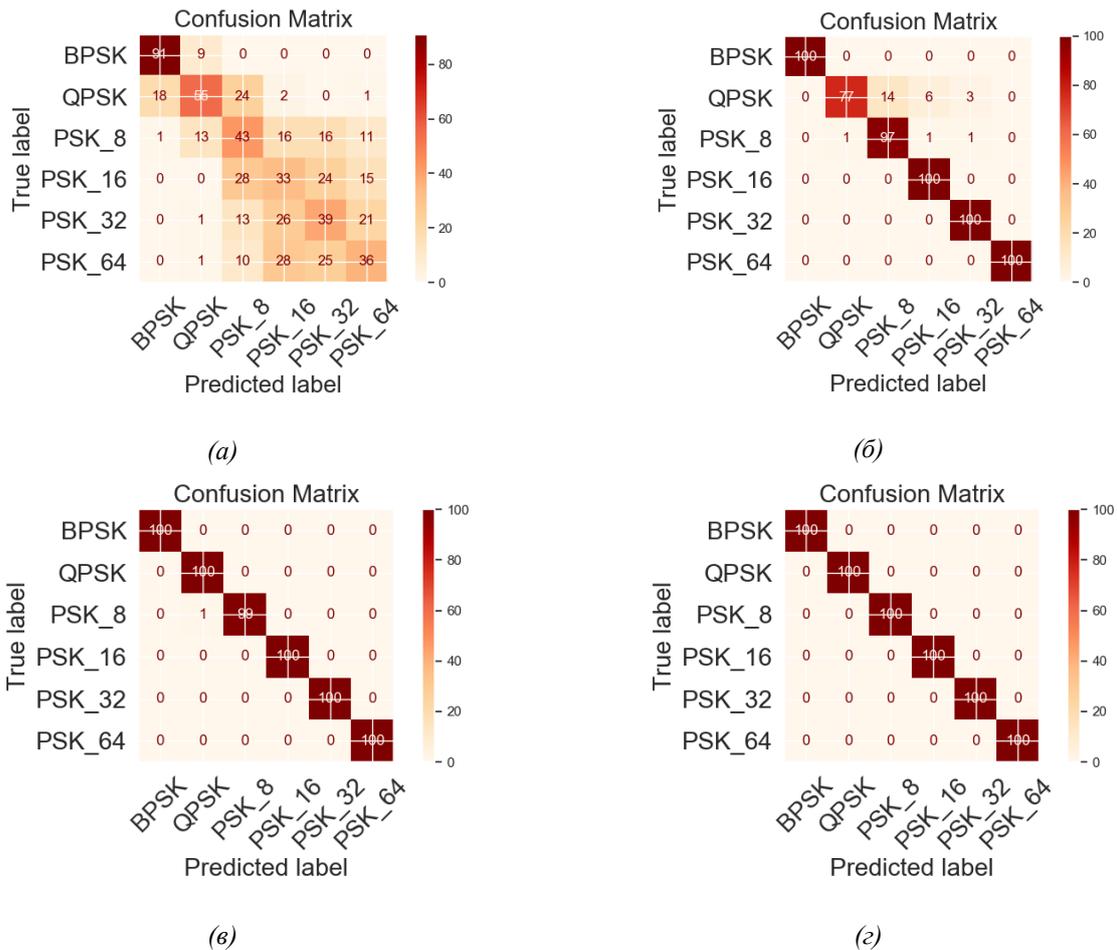


Рисунок 6. Матрицы ошибок для различных отношений сигнал/шум (а- 0 dB, б – 5dB, в-10dB, г-15dB)

Экспериментальные результаты демонстрируют высокую эффективность предложенного подхода, особенно в условиях низкого соотношения сигнал/шум, где CNN показала способность достигать точности классификации выше 99,9% для большинства типов модуляций, кроме QPSK, где точность составила 94,5%. Такие результаты подтверждают потенциал глубокого обучения в задачах распознавания модуляции, предлагая значительные перспективы для практического применения в сфере цифровой связи.

Основной вклад статьи включает в себя разработку упрощенной архитектуры CNN и формирование уникальной базы данных, что в совокупности обеспечивает выдающуюся точность классификации. Достижение такой высокой точности обусловлено использованием разнообразных сверточных ядер, минимизации ошибок и применении активационных функций, таких как ReLU, что позволяет сети эффективно обрабатывать и классифицировать модулированные сигналы.

В заключение, статья акцентирует внимание на необходимости дальнейшего совершенствования и упрощения сетевых архитектур, сохраняя при этом высокую точность распознавания. Это предполагает изучение способов обобщения модели на различные условия и наборы данных, а также разработку методик для эффективного развертывания моделей в реальных условиях эксплуатации, что открывает путь для будущих исследований в области автоматического распознавания цифровой модуляции.

Список использованных источников

- [1] Young A. F. *Classification of digital modulation types in multipath environments* // Master's Thesis. Naval Postgraduate School, Monterey, CA 93943-5000, California. - 2008. -pp. 1 – 65.
- [2] Fengyuan S., Chunsheng S., Chao H. A lightweight and efficient neural network for modulation recognition // *Digital Signal Processing*. – 2022. – Vol. 123, -pp 103444. <https://doi.org/10.1016/j.dsp.2022.103444>
- [3] Zhang Z., Wang C., Gan C., Sun S. and Wang M. Automatic modulation classification using convolutional neural network with features fusion of SPWVD and BJD // *IEEE Transactions on Network and Service Management*. - 2019. - Vol. 5, № 3, - pp. 469-478. <https://doi.org/10.1109/TSIPN.2019.2900201>
- [4] Huang S., Yao Y., Wei Z., Feng Z. and Zhang P. Automatic modulation classification of overlapped sources using multiple cumulants // *IEEE*. - 2016. - Vol. 66, № 7, - pp. 6089-6101. <https://doi.org/10.1109/TVT.2016.2636324>
- [5] Аджемов С.С., Кленов Н.В., Терешонок М.В., Чиров Д.С. Методы распознавания видов цифровой модуляции сигналов в когнитивных радиосистемах // *Вестник Московского Университета. Серия 3. Физика. Астрономия*. - 2015. № 6, - с. 19-27.
- [6] Bijan G. M. *Digital modulation classification using constellation shape* // *Signal Processing*. - 2000. - Vol. 80, № 2, - pp. 251-277. [https://doi.org/10.1016/S0165-1684\(99\)00127-9](https://doi.org/10.1016/S0165-1684(99)00127-9)
- [7] Chaithanya V., Reddy V.U. *Blind modulation classification in the presence of carrier frequency offset* // Master's Thesis. Communications Research Center. - 2010. - pp. 1-39. <https://doi.org/10.1109/SPCOM.2010.5560548>
- [8] Changbo H., Yuqian L., Xiang Ch., Jing Zh. Automatic modulation classification using KELM with joint features of CNN and LBP // *Physical Communication*. - 2021. - Vol. 45, -pp. 101259. <https://doi.org/10.1016/j.phycom.2020.101259>
- [9] Aceto G., Ciuonzo D., Montieri A., Pescapé A. Mobile encrypted traffic classification using deep learning: experimental evaluation, lessons learned, and challenges // *IEEE Transactions on Network and Service Management*. - 2019. - pp. 445-458. <https://doi.org/10.1109/TNSM.2019.2899085>
- [10] Purwins H., Li B., Virtanen T., Schlüter J., Chang S.Y. and Sainath T. Deep learning for audio signal processing // *IEEE Journal of Selected Topics in Signal Processing*. – 2019. - Vol. 13, № 2, - pp. 206-219. <https://doi.org/10.1109/JSTSP.2019.2908700>
- [11] Bagga J., Tripathi N. Automatic modulation classification using statistical features in fading environment // *International Journal of Advanced Research in electrical, electronics and instrumentation engineering*. - 2013. - Vol. 2, № 8, - pp. 3701- 3708.
- [12] Meng F., Chen P., Wu L. and Wang X. Automatic modulation classification: A deep learning enabled approach // *IEEE Transactions on Vehicular Technology*. - 2018. - Vol. 67, № 11, - pp. 10760-10772. <https://doi.org/10.1109/TVT.2018.2868698>
- [13] Wang Y., Liu M., Yang J. and Gui G. Data-driven deep learning for automatic modulation recognition in cognitive radios // *IEEE Transactions on Vehicular Technology*. - 2019. - Vol. 68, № 4, - pp. 4074-4077. <https://doi.org/10.1109/TVT.2019.2900460>
- [14] Qi P., Zhou X., Zheng S. and Li Z. Automatic modulation classification based on deep residual networks with multimodal information // *IEEE Transactions on Cognitive Communications and Networking*. - 2021. - Vol. 7, № 1, - pp. 21-33. <https://doi.org/10.1109/TCCN.2020.3023145>
- [15] Swami A., Sadler B.M. Hierarchical digital modulation classification using cumulants // *IEEE Transactions on Communications*. - 2000. - Vol. 48, № 3, - pp. 416-429. <https://doi.org/10.1109/26.837045>
- [16] Chen H., Guo L., Dong C., Cong F. and Mu X. Automatic modulation classification using multi-scale convolutional neural network // *IEEE International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*. -2020. - pp. 1-6. <https://doi.org/10.1109/PIMRC48278.2020.9217305>
- [17] Namaz T., Alzahrani A. Machine-Learning-Assisted Cyclostationary Spectral Analysis for Joint Signal Classification and Jammer Detection at the Physical Layer of Cognitive Radio // *Sensors*. - 2023. -pp. 7144. <https://doi.org/10.3390/s23167144>

References

- [1] Young A. F. *Classification of digital modulation types in multipath environments* // Master's Thesis. Naval Postgraduate School, Monterey, CA 93943-5000, California. - 2008. -pp. 1 – 65.

- [2] Fengyuan S., Chunsheng S., Chao H. A lightweight and efficient neural network for modulation recognition // *Digital Signal Processing*. – 2022. – Vol. 123, -pp. 103444. <https://doi.org/10.1016/j.dsp.2022.103444>
- [3] Zhang Z., Wang C., Gan C., Sun S. and Wang M. Automatic modulation classification using convolutional neural network with features fusion of SPWVD and BJD // *IEEE Transactions on Network and Service Management*. - 2019. - Vol. 5, № 3, - pp. 469-478. <https://doi.org/10.1109/TSIPN.2019.2900201>
- [4] Huang S., Yao Y., Wei Z., Feng Z. and Zhang P. Automatic modulation classification of overlapped sources using multiple cumulants // *IEEE*. - 2016. - Vol. 66, № 7, - pp. 6089-6101. <https://doi.org/10.1109/TVT.2016.2636324>
- [5] Adzhemov S.S., Klenov N.V., Tereshonok M.V., Chirov D.S. Methods for recognizing types of digital signal modulation in cognitive radio systems // *Bulletin of Moscow University. Series 3. Physics and Astronomy*. - 2015. № 6, - pp. 19-27.
- [6] Bijan G. M. Digital modulation classification using constellation shape // *Signal Processing*. - 2000. - Vol. 80, № 2, - pp. 251-277. [https://doi.org/10.1016/S0165-1684\(99\)00127-9](https://doi.org/10.1016/S0165-1684(99)00127-9)
- [7] Chaithanya V., Reddy V.U. Blind modulation classification in the presence of carrier frequency offset // *Master's Thesis. Communications Research Center*. - 2010. - pp. 1-39. <https://doi.org/10.1109/SPCOM.2010.5560548>
- [8] Changbo H., Yuqian L., Xiang Ch., Jing Zh. Automatic modulation classification using KELM with joint features of CNN and LBP // *Physical Communication*. - 2021. - Vol. 45, -pp 101259. <https://doi.org/10.1016/j.phycom.2020.101259>
- [9] Aceto G., Ciunzo D., Montieri A., Pescapé A. Mobile encrypted traffic classification using deep learning: experimental evaluation, lessons learned, and challenges // *IEEE Transactions on Network and Service Management*. - 2019. - pp. 445-458. <https://doi.org/10.1109/TNSM.2019.2899085>
- [10] Purwins H., Li B., Virtanen T., Schlüter J., Chang S.Y. and Sainath T. Deep learning for audio signal processing // *IEEE Journal of Selected Topics in Signal Processing*. – 2019. - Vol. 13, № 2, - pp. 206-219. <https://doi.org/10.1109/JSTSP.2019.2908700>
- [11] Bagga J., Tripathi N. Automatic modulation classification using statistical features in fading environment // *International Journal of Advanced Research in electrical, electronics and instrumentation engineering*. - 2013. - Vol. 2, № 8, - pp. 3701- 3708.
- [12] Meng F., Chen P., Wu L. and Wang X. Automatic modulation classification: A deep learning enabled approach // *IEEE Transactions on Vehicular Technology*. - 2018. - Vol. 67, № 11, - pp. 10760-10772. <https://doi.org/10.1109/TVT.2018.2868698>
- [13] Wang Y., Liu M., Yang J. and Gui G. Data-driven deep learning for automatic modulation recognition in cognitive radios // *IEEE Transactions on Vehicular Technology*. - 2019. - Vol. 68, № 4, - pp. 4074-4077. <https://doi.org/10.1109/TVT.2019.2900460>
- [14] Qi P., Zhou X., Zheng S. and Li Z. Automatic modulation classification based on deep residual networks with multimodal information // *IEEE Transactions on Cognitive Communications and Networking*. - 2021. - Vol. 7, № 1, - pp. 21-33. <https://doi.org/10.1109/TCCN.2020.3023145>
- [15] Swami A., Sadler B.M. Hierarchical digital modulation classification using cumulants // *IEEE Transactions on Communications*. - 2000. - Vol. 48, № 3, - pp. 416-429. <https://doi.org/10.1109/26.837045>
- [16] Chen H., Guo L., Dong C., Cong F. and Mu X. Automatic modulation classification using multi-scale convolutional neural network // *IEEE International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*. -2020. - pp. 1-6. <https://doi.org/10.1109/PIMRC48278.2020.9217305>
- [17] Namaz T., Alzahrani A. Machine-Learning-Assisted Cyclostationary Spectral Analysis for Joint Signal Classification and Jammer Detection at the Physical Layer of Cognitive Radio // *Sensors*. - 2023. -pp. 7144. <https://doi.org/10.3390/s23167144>