

Об особенностях применения нейронных сетей для классификации SEFDM сигналов по сигнальным созвездиям

И. Н. Горбунов¹, В. А. Павлов², С. В. Завьялов³, А. А. Белов⁴

Санкт-Петербургский политехнический университет Петра Великого

¹gorbunov.in@edu.spbstu.ru, ²pavlov_va@spbstu.ru, ³zavyalov_sv@spbstu.ru, ⁴belov@spbstu.ru

Аннотация. В статье рассматривается применение сверточной нейронной сети для классификации типов модуляций сигналов SEFDM с использованием изображений сигнальных созвездий. Метод был протестирован на типах модуляций BPSK и QPSK при различных отношениях сигнал/шум (от 0 до 20 дБ). Точность классификации составила более 97 %.

Ключевые слова: сверточная нейронная сеть, CNN, SEFDM, глубокое обучение, диаграмма созвездия, модуляция, классификация

I. ВВЕДЕНИЕ

Быстрый рост интереса к новым системам связи, таким как «5G» и «6G» [1], [2], побуждает к разработке различных новых технологий обработки сигналов. К таким технологиям относятся возможность автоматической классификации используемых схем модуляции [3] и применение методов машинного обучения. Данные технологии делают возможным построение интеллектуальных систем связи, примерами которых являются адаптивные и когнитивные радиоприемники, а также автоматические системы радиочастотного мониторинга.

В последние десятилетия для автоматической классификации типов модуляции наибольшую практическую применимость получили методы, основанные на выделении признаков [4]–[8]. Такие алгоритмы состоят из двух основных этапов: выделение характерных признаков из принятого сигнала и определение типа модуляции по этим признакам. Такой подход даёт сочетание высокой производительности со сравнительно низкой вычислительной сложностью. Дополнительным достоинством данных методов является то, что они не нуждаются в априорной информации о параметрах сигнала и статистике канала [9], [10].

Проблема автоматической классификации для одночастотных систем связи широко рассматривается в литературе [4]–[6]. Однако в настоящее время существует относительно немного работ по классификации для систем с многочастотными сигналами [7]–[12]. Использование многочастотных сигналов, в частности сигналов SEFDM, является одним из принципов построения сетей пятого поколения и рассматривается во многих работах [13]–[16].

Результаты работы получены при поддержке стипендии Президента Российской Федерации молодым ученым и аспирантам, осуществляющих перспективные научные исследования и разработки по приоритетным направлениям модернизации российской экономики на 2021–2023 годы (СП-1671.2021.3).

В [11] авторы используют статистические признаки, а также адаптивную вейвлет энтропию и кумулянты до четвертого порядка для классификации сигналов OFDM. При таком подходе достигается точность классификации 99 % для следующих типов модуляции: BPSK, QPSK, 16-, 64-, 256-, 1024-QAM. В [12] был предложен метод, основанный на глубоком обучении, позволяющий находить степень сжатия сигналов SEFDM для различных схем модуляции с точностью не ниже 98%. В отличие от некоторых других, в этой работе исследовался канал Рэя с замираниями (модель пешехода), а не только простой канал AWGN. Метод, предложенный в [17], основан на использовании сверточных нейронных сетей (CNN). Входными данными являются изображения сигнальных созвездий. Авторы протестировали свой метод на широком диапазоне типов модуляции, включая амплитудную модуляцию, фазовую модуляцию и квадратурную амплитудную модуляцию. Экспериментальная точность классификации в ряде случаев оказалась 100 %. Но авторы ограничились рассмотрением одночастотных сигналов. В [18] Т. Ху и I. Darwazeh применили сверточные нейронные сети для определения коэффициента уплотнения сигналов SEFDM с фиксированным типом модуляции (QPSK). Точность распознавания составила около 95 % при ОСШ 20 дБ. В [19] для классификации коэффициентов уплотнения используются вейвлет признаки и ансамбль опорных векторов (SVM). Следует отметить, что в работах [18], [19] использовался только один тип модуляции QPSK. В работе [12] сверточная нейронная сеть используется для классификации коэффициентов уплотнения при разных типах модуляций (BPSK, QPSK, QAM16, QAM64), но сами типы модуляции при этом не распознаются.

Таким образом среди рассматриваемой выборки статей не удалось найти исследований, посвящённых классификации типов модуляций при различных коэффициентах уплотнения.

Целью данной работы является применение методов глубокого обучения для классификации типов модуляции сигналов SEFDM с использованием изображений сигнальных созвездий.

II. ОПИСАНИЕ МОДЕЛИ

A. Блок-схема модели

Для разработки классификатора и проверки его работы была реализована имитационная модель передатчика и приемника сигналов SEFDM. Блок-схема этой модели представлена на рис. 1. Сигнал SEFDM формируется из битового потока с выбранным типом модуляции поднесущих. Алгоритм обратного быстрого преобразования Фурье (ОБПФ) используется для

переноса сигнала во временную область, после чего происходит уплотнение поднесущих. Далее модулированный сигнал передается по каналу связи. На приемной стороне после прямого быстрого преобразования Фурье (БПФ) формируется изображение сигнального созвездия и определяется тип модуляции принимаемого сигнала. Далее решение классификатора сравнивается с метками классов и оценивается точность классификации.



Рис. 1. Блок-схема имитационной модели передатчика и приёмника SEFDM сигналов

Дискретный сигнал SEFDM, в соответствии с [20], математически представляется в виде:

$$X[k] = \frac{1}{\sqrt{Q}} \sum_{n=0}^{N-1} s_n \exp\left(\frac{j2\pi n k \alpha}{Q}\right),$$

где $X[k]$ – k -я временная выборка сигнала, где $k = [0, 1, \dots, Q-1]$, s_n – символ, модулированный на n -й поднесущей и α – коэффициент уплотнения.

Информационная последовательность модулируется одним из двух типов модуляции: BPSK и QPSK. Каждый символ SEFDM состоит из 128 поднесущих. В качестве канала связи использовался канал с аддитивным белым гауссовым шумом. Значения E_b/N_0 (отношения сигнал/шум) варьировались от 0 до 20 дБ. В ходе тестирования классификация производилась по каждому символу SEFDM ($\alpha = 1, 0,95, 0,9$). Размер выборки составлял 10 000 примеров для каждого значения отношения сигнал/шум.

В. Архитектура нейронной сети

Обзор и анализ литературы показал [12], [18], [19], что наиболее эффективным для задач классификации является применение сверточных нейронных сетей. В результате экспериментов была выбрана архитектура, позволяющая добиться высокой точности при небольших вычислительных затратах, которая представлена на рис. 2. Комбинация «сверточный слой, слой ReLU, слой пакетной нормализации, слой передискретизации» – это есть типичный, устоявшийся в задачах классификации подход. На вход подается изображение сигнального созвездия с разрешением 256×256 пикселей. Сеть состоит из трех сверточных слоев с размером фильтра 3×3 и количеством фильтров

32 в каждом слое. За каждым сверточным слоем следует функция активации ReLU, слой пакетной нормализации и слой передискретизации. В качестве классификатора используется полносвязная нейронная сеть, состоящая из 128 нейронов. Выходному слою предшествует слой с нейронами, количество которых соответствует числу распознаваемых классов. Последний слой – softmax. Таким образом, на выходе сети имеем два значения в диапазоне от 0 до 1. Порядковый номер выходного нейрона, выдавшего наибольшее значение, является номером предсказанного класса.

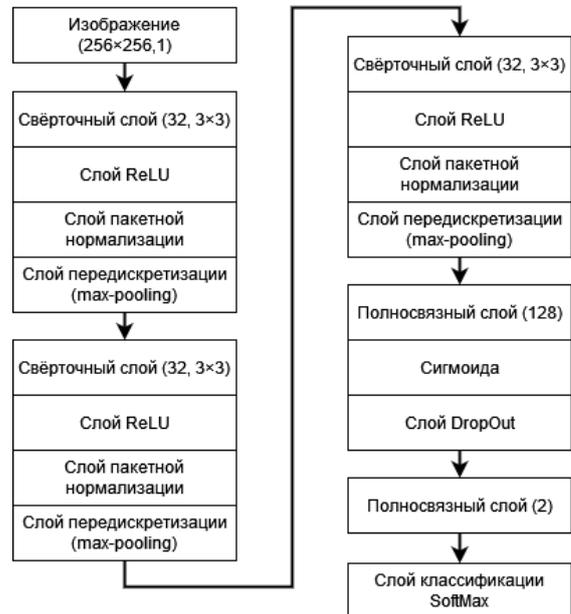


Рис. 2. Архитектура нейронной сети

С. Оценка вычислительной сложности

Вычислительная сложность для одного сверточного слоя вычисляется, как количество операций сложения и умножения:

$$O = m \times N \times S_f \times S_f \times c \times H_{out} \times W_{out},$$

где N – количество фильтров, S_f – размер фильтров, c – количество каналов, H_{out} и W_{out} – высота и ширина карты признаков после свертки, $m = 2$ – количество операций (сложение и умножение).

Вычислительная сложность для одного полносвязного слоя определяется по формуле:

$$O = m \times S_{in} \times n,$$

где S_{in} – размер входного вектора данных, n – количество нейронов в слое.

Таким образом, для всех слоев предлагаемой нейронной сети вычислительная сложность составляет $112,2 \cdot 10^6$ операций сложения и умножения (FLOPs). К примеру, для процессора Xeon E3-1275 (4 cores @ 3.574GHz) с производительностью $114 \cdot 10^9$ FLOP/sec это означает, что на одну итерацию классификации у него уйдет 982,5 мкс.

III. РЕЗУЛЬТАТЫ

Аппаратное обеспечение, используемое для классификации, включает ресурсы Суперкомпьютерного центра Санкт-Петербургского политехнического

университета Петра Великого и персональный компьютер с графическим процессором NVIDIA GeForce GTX 2080 TI и процессором Core i7.

На рис. 3 показаны примеры сигнальных созвездий QPSK для различных отношений сигнал-шум и коэффициентов уплотнения.

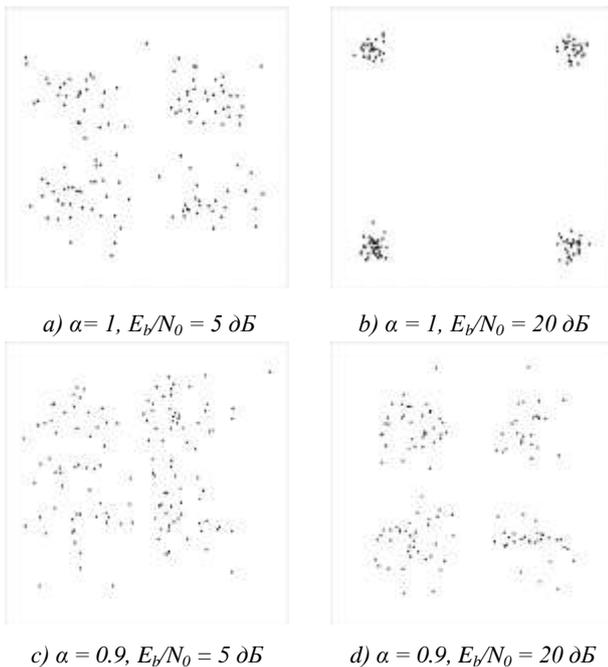


Рис. 3. Пример сигнальных созвездий (QPSK) для разных значений E_b/N_0 (отношение сигнал шум)

Для тестирования классификатора использовались изображения сигнальных созвездий, полученные при разных коэффициентах уплотнения (1; 0,95 и 0,9) и при разных отношениях сигнал/шум в диапазоне от 9 до 20 дБ. Для каждого значения отношения сигнал/шум формировалось 1000 изображений.

На рис. 4 показана матрица ошибок, которая является одной из характеристик корректности работы классификатора и представляет комбинацию прогнозируемых и истинных значений.

Тестовый набор данных содержал сигналы со значениями отношения сигнал/шум в диапазоне от 0 до 20 дБ и тремя коэффициентами сжатия ($\alpha = 1; 0,95; 0,9$). По выходным значениям нейронной сети тип модуляции сигнала определялся следующим образом: решение принималось в пользу BPSK, если большее значение появлялось на первом выходном нейроне, и в пользу QPSK в обратном случае. Причём предложенный классификатор является универсальным для любого из трёх рассмотренных коэффициентов уплотнения.

Точность классификации для обоих классов составила 97 %. На рис. 5 показана зависимость точности от отношения сигнал/шум. Эта зависимость показывает, что уже начиная с $E_b/N_0 = 7$ дБ точность распознавания для обоих типов модуляции становится выше 99 %.

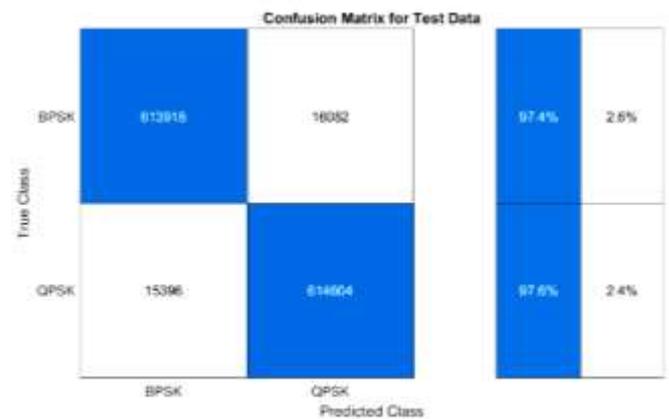


Рис. 4. Матрица ошибок для тестового набора данных

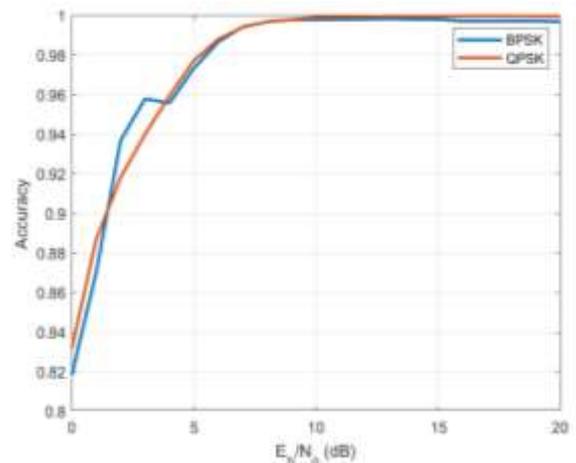


Рис. 5. Зависимость точности классификации от E_b/N_0 (отношения сигнал/шум)

IV. ЗАКЛЮЧЕНИЕ

В статье предлагается метод классификации типов модуляции для сигналов SEFDM на основе сверточной нейронной сети и изображений сигнальных созвездий. Метод был протестирован на модуляциях BPSK и QPSK при различных отношениях сигнал/шум (от 0 до 20 дБ). Точность классификации составила более 97 %. Данный подход может быть использован при разработке адаптивных приёмников на базе программно определяемых радиосистем.

БЛАГОДАРНОСТЬ

Результаты работы получены с использованием вычислительных ресурсов Суперкомпьютерного центра Санкт-Петербургского политехнического университета Петра Великого (www.spbstu.ru).

СПИСОК ЛИТЕРАТУРЫ

- [1] A. Ghosh, A. Maeder, M. Baker and D. Chandramouli, "5G Evolution: A View on 5G Cellular Technology Beyond 3GPP Release 15," in IEEE Access, vol. 7, pp. 127639-127651, 2019, doi: 10.1109/ACCESS.2019.2939938.
- [2] F. Rinaldi et al., "Non-Terrestrial Networks in 5G & Beyond: A Survey," in IEEE Access, vol. 8, pp. 165178-165200, 2020, doi: 10.1109/ACCESS.2020.3022981.

- [3] Z. Zhu, A.K. Nandi, "Automatic Modulation Classification. Principles, Algorithms and Applications", Wiley, 184 p., 2015.
- [4] M. Oner, O.A. Dobre, On the second-order cyclic statistics of signals in the presence of receiver impairments. *IEEE Trans. Commun.* 59(12), 3278–3284 (2011)
- [5] S. Majhi, R. Gupta, W. Xiang, Novel blind modulation classification of circular and linearly modulated signals using cyclic cumulants, in 2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). (IEEE, 2017), pp. 1–5
- [6] P. Daponte, G. Mercurio, S. Rapuano, A wavelet networks-based method for the digital telecommunication system monitoring. *IEEE Trans. Instrum. Meas.* 50(6), 1773–1780 (2001)
- [7] A.D. Pambudi, S. Tjondronegoro, H. Wijanto, Statistical properties proposed for blind classification OFDM modulation scheme, in IEEE International Conference on Aerospace Electronics and Remote Sensing Technology (IEEE, 2014), pp. 89–93
- [8] D. Shimbo, I. Oka, A modulation classification using amplitude moments in OFDM systems, in International Symposium On Information Theory & Its Applications, (IEEE, 2010), pp. 288–293
- [9] R. Gupta, S. Kumar, S. Majhi, Blind modulation classification for OFDM in the presence of timing, frequency, and phase offsets, in IEEE 90th Vehicular Technology Conference (VTC2019-Fall) (IEEE, 2019), pp. 1–5
- [10] R. Gupta, S. Kumar, S.Majhi, Blind modulation classification for asynchronous OFDM systems over unknown signal parameters and channel statistics. *IEEE Trans. Veh. Technol.* 69(5), 5281–5292 (2020)
- [11] Gorbunov I.N., Pavlov V.A., Zavjalov S.V., Ge D. (2022) On the Classification of OFDM Signals Modulation Types Using Neural Networks. In: Velichko E., Kapralova V., Karaseov P., Zavjalov S., Angueira P., Andreev S. (eds) International Youth Conference on Electronics, Telecommunications and Information Technologies. Springer Proceedings in Physics, vol. 268. Springer, Cham. https://doi.org/10.1007/978-3-030-81119-8_5
- [12] Pavlov, V. A., Zavjalov, S. V., Volvenko, S. V., & Gorlov, A. (2021, October). Deep Learning Application for Classification of SEFDM Signals. In 2021 International Conference on Electrical Engineering and Photonics (EExPolytech) (pp. 28-31). IEEE.
- [13] E.N. Smirnova, A.S. Ovsyannikova, S.V. Zavjalov, G. Dong, On features of implementation of SEFDM-transmitter with optimal shape of envelope. *J. Phys. Conf. Ser.* 1236(1), 1–6 (2019), art. № 012067. <https://doi.org/10.1088/1742-6596/1236/1/012067>
- [14] E.N. Smirnova, Experimental research of receiver based on SEFDM-signals with optimal envelopes. *J. Phys. Conf. Ser.* 1326(1), 1–5 (2019), art. № 012031. <https://doi.org/10.1088/1742-6596/1326/1/012031>
- [15] A. Kislitsyn, A. Krylov, A. Rashich, Experimental evaluation of SEFDM trellis based demodulator, in IEEE International Conference on Electrical Engineering and Photonics (EExPolytech), St. Petersburg, Russia (2020), pp. 110–113. <https://doi.org/10.1109/EExPolytech50912.2020.9243960>
- [16] A. Gelgor, V.P. Nguyen, Outperforming conventional OFDM and SEFDM signals by means of using optimal spectral pulses and the M-BCJR algorithm, in 2019 26th International Conference on Telecommunications (ICT). (IEEE, 2019), pp. 130–134
- [17] Peng, Shengliang, et al. "Modulation classification based on signal constellation diagrams and deep learning." *IEEE transactions on neural networks and learning systems* 30.3 (2018): 718-727.
- [18] T. Xu and I. Darwazeh, "Deep Learning for Over-the-Air Non-Orthogonal Signal Classification," 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring), 2020, pp. 1-5, doi: 10.1109/VTC2020-Spring48590.2020.9128869.
- [19] T. Xu and I. Darwazeh, "Wavelet Classification for Non-Cooperative Non-Orthogonal Signal Communications," 2020 IEEE Globecom
- [20] Luo, Fa-Long, and Charlie Jianzhong Zhang, eds. Signal processing for 5G: algorithms and implementations. John Wiley & Sons, 2016.