

Радиотехнические средства передачи, приема и обработки сигналов

Статья посвящена 80-летию факультета радиотехники и телекоммуникаций

УДК 621.391

Научная статья

<https://doi.org/10.32603/1993-8985-2025-28-3-11-23>

Гибко конфигурируемый модульный нейросетевой OFDM-приемник

А. Б. Сергиенко[✉], П. В. Апалина, А. Д. Лебединская

Санкт-Петербургский государственный электротехнический университет "ЛЭТИ"
им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

[✉] absergienko@etu.ru

Аннотация

Введение. Ортогональное частотное мультиплексирование (OFDM) является доминирующей схемой модуляции в мобильной связи. OFDM-системы должны быть работоспособны в широком диапазоне свойств многолучевого канала связи с замираниями. В последнее время активно развиваются подходы к построению OFDM-приемников на основе методов машинного обучения, в том числе искусственных нейронных сетей. Как правило, нейросети в таких приемниках обучаются для одной конкретной конфигурации системы связи. Это затрудняет использование нейросетевых приемников в реальных системах и делает актуальной задачу разработки более гибких схем.

Цель работы. Получить и оптимизировать структуру OFDM-приемника, основанного на искусственной нейросети и состоящего из отдельных модулей, комбинируемых в зависимости от конфигурации пилот-сигналов и используемого вида модуляции.

Материалы и методы. Приведенные результаты получены с помощью компьютерного моделирования в среде MATLAB.

Результаты. Предложенная архитектура нейросетевого OFDM-приемника основана на комбинации двух многослойных перцептронов, первый из которых в неявной форме реализует оценку состояния канала связи и компенсацию искажений, а второй осуществляет демодуляцию. При этом первый перцептрон формирует промежуточные представления символов данных, для которых при обучении сети не было конкретных образцов, а экземпляры второго перцептрона работают с этими представлениями для отдельных символов данных. Варианты второго перцептрона были обучены для трех видов квадратурной амплитудной модуляции (КАМ): КАМ-4, КАМ-16 и КАМ-64.

Заключение. Разработанный OFDM-приемник для всех рассмотренных видов модуляции обеспечил частоту ошибок, сравнимую с результатами базовых алгоритмов при благоприятных условиях канала (умеренный разброс задержек при низком доплеровском разбросе), и превзошел базовые показатели в тяжелых условиях (канал с большим разбросом задержек и высоким доплеровским разбросом). Возможные направления дальнейшего развития предлагаемого подхода – нейросетевое формирование мягких решений демодулятора и разработка специализированных слоев нейросети, облегчающих аппроксимацию необходимых операций.

Ключевые слова: ортогональное частотное мультиплексирование, оценка канала, совместная оценка канала и демодуляция данных, квадратурная амплитудная модуляция, глубокое обучение, многослойный перцептрон

Для цитирования: Сергиенко А. Б., Апалина П. В., Лебединская А. Д. Гибко конфигурируемый модульный нейросетевой OFDM-приемник // Изв. вузов России. Радиоэлектроника. 2025. Т. 28, № 3. С. 11–23.

doi: 10.32603/1993-8985-2025-28-3-11-23

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Источник финансирования. Исследование выполнено в СПбГЭТУ "ЛЭТИ" за счет гранта Российского научного фонда № 24-29-00560, <https://rscf.ru/project/24-29-00560/>.

Статья поступила в редакцию 06.12.2024; принята к публикации после рецензирования 18.04.2025; опубликована онлайн 30.06.2025



Flexible Configurable Modular Neural Network-Based OFDM Receiver

Alexander B. Sergienko✉, Polina V. Apalina, Anastasia D. Lebedinskaya

Saint Petersburg Electrotechnical University, St Petersburg, Russia

✉ absrgienko@etu.ru

Abstract

Introduction. Orthogonal frequency division multiplexing (OFDM) is the dominant modulation scheme in mobile communications. OFDM systems should be capable of operating across a wide range of multipath fading channel conditions. The recent research focus in this field has been on the design of OFDM receivers based on machine learning, including artificial neural networks. Neural networks in such receivers are typically trained for one specific communication system configuration. This complicates the use of neural network-based receivers in real-world systems, thus rendering development of more flexible schemes highly relevant.

Aim. To obtain and optimize the structure of an OFDM receiver based on an artificial neural network and consisting of separate modules that can be combined depending on the configuration of the pilot signals and the modulation used.

Materials and methods. Computer simulation in the MATLAB environment.

Results. The proposed architecture of a neural network-based OFDM receiver uses a combination of two multilayer perceptrons, one of which implicitly implements channel state information estimation and equalization, and the other performs demodulation. The first perceptron forms intermediate representations of data symbols, for which there were no specific references during network training, while the instances of the second perceptron work with these representations for individual data symbols. Variants of the second perceptron were trained for three quadrature modulation (QAM) constellations: 4QAM, 16QAM, and 64QAM.

Conclusion. The proposed OFDM receiver for all considered modulation types provided error rates comparable to those of the baseline algorithms under favorable channel conditions (moderate delay spread with low Doppler spread) and outperformed baseline algorithms in severe conditions (channel with a large delay spread and high Doppler spread). Further research directions involve neural network-based generation of soft decisions of the demodulator and development of specialized layers of the neural network that would facilitate approximation of the necessary operations.

Keywords: orthogonal frequency division multiplexing, channel estimation, joint channel estimation and data demodulation, quadrature amplitude modulation, deep learning, multilayer perceptron

For citation: Sergienko A. B., Apalina P. V., Lebedinskaya A. D. Flexible Configurable Modular Neural Network-Based OFDM Receiver. Journal of the Russian Universities. Radioelectronics. 2025, vol. 28, no. 3, pp. 11–23.
doi: 10.32603/1993-8985-2025-28-3-11-23

Conflict of interest. The authors declare no conflicts of interest.

Source of funding. This research was carried out at Saint Petersburg Electrotechnical University and supported by the Russian Science Foundation under grant No. 24-29-00560, <https://rscf.ru/en/project/24-29-00560/>.

Submitted 06.12.2024; accepted 18.04.2025; published online 30.06.2025

Введение. Ортогональное частотное мультиплексирование (Orthogonal Frequency Division Multiplexing – OFDM) в настоящее время является доминирующей схемой модуляции в мобильной связи. Оно используется в качестве технологии физического уровня в мобильных сетях четвертого (LTE [1]) и пятого (NR [2]) поколений. В будущих поколениях этих сетей OFDM, по-видимому, сохранит свое доминирующее положение, несмотря на развитие дру-

гих схем модуляции, поскольку, как указано в [3], "не появилось ни одной другой формы сигнала, демонстрирующей существенные преимущества по сравнению с OFDM и мотивирующей к другому выбору" ("No other waveform showing substantial gains over OFDM motivating a different choice has emerged").

Для достижения высокой спектральной эффективности OFDM используется в сочетании с видами модуляции, требующими когерентно-

го приема. Это, в свою очередь, требует наличия информации о состоянии канала связи (Channel State Information – CSI) на приемной стороне. Таким образом, классическая процедура приема OFDM-сигнала включает в себя следующие отдельные этапы: оценку CSI, компенсацию искажений и демодуляцию данных. При этом приемник должен быть работоспособным в широком диапазоне свойств многолучевого канала связи с замираниями.

В последнее время большое внимание привлекли подходы к приему OFDM-сигнала, основанные на нейронных сетях. Рассматриваются различные концепции, среди которых замена отдельных блоков в классическом приемнике обучаемыми нейронными сетями, а также совместная оптимизация нескольких операций.

Один из возможных подходов – повышение качества оценки CSI с помощью нейронных сетей. Эта проблема обычно рассматривается как задача обработки изображений, которая сочетает в себе масштабирование изображения и его очистку от шума. Предлагаемые решения основаны на сверточных нейронных сетях [4], также используются остаточное обучение [5], генеративные состязательные сети [6], сети с долгой кратковременной памятью [7], сети сжатия и реконструкции [8].

Более сложный подход рассмотрен в [9], где нейронные сети заменяют несколько отдельных блоков OFDM-приемника. В предложенной структуре используются 3 отдельные обучаемые сети, которые выполняют оценку CSI, демодуляцию квадратурной амплитудной модуляции (КАМ) и декодирование помехоустойчивого кода.

В [10] используется единая нейронная сеть для совместного выполнения оценки канала, компенсации искажений и демодуляции данных. Сеть использует архитектуру многослойного перцептрона (MultiLayer Perceptron – MLP). Она обрабатывает очень короткие порции OFDM-сигнала (два OFDM-символа во временной области с 64 поднесущими). Описанный способ требует частого размещения пилот-символов во временной области и не может быть непосредственно использован с режимами модуляции, отличными от бинарной или квадратурной фазовой манипуляции (ФМ), где для принятия решений о значениях битов до-

статочно определить знаки величин, полученных после компенсации искажений.

В [11] исследуется концепция непрерывного переобучения приемника OFDM на основе нейронной сети. Это переобучение позволяет приемнику адаптироваться к новым непредвиденным свойствам канала связи. Сам приемник основан на рекуррентной нейронной сети. Показано, что такая адаптивность обеспечивает некоторый выигрыш в производительности по сравнению с универсальным приемником, особенно в экстремальных сценариях, выходящих за рамки предусмотренных требований.

Также предпринимаются попытки заменить весь приемник OFDM, включая операцию быстрого преобразования Фурье (БПФ), одной нейронной сетью [12].

Анализ публикаций показывает, что нейросети, используемые в них для приема OFDM-сигналов, обучаются для применения в одной конкретной конфигурации системы связи – фиксированными являются число поднесущих, количество и размещение пилот-символов, вид модуляции. Ниже приводятся некоторые примеры:

- [4–6]: 72 поднесущие, 14 OFDM-символов;
- [7, 10]: 64 поднесущие, 2 OFDM-символа, модуляция КАМ-4;
- [8]: 72 поднесущие, 28 OFDM-символов, модуляция КАМ-256;
- [9]: 52 поднесущие, модуляция КАМ-16;
- [11]: 64 поднесущие, 36 OFDM-символов, модуляция КАМ-16.

При таком подходе для каждой возможной конфигурации системы необходима соответствующая обученная нейросеть. Это может быть приемлемо для нестандартных систем конкретного назначения, имеющих единственную возможную конфигурацию, однако плохо подходит для систем, где параметры конфигурации, такие, как, например, схема модуляции и кодирования, адаптируются к текущим условиям. Цель исследований авторов статьи – решить данную проблему декомпозицией нейросетевого приемника на модули, выполняющие разные функции. В результате была предложена структура, обладающая следующими чертами:

- явные процедуры оценки CSI и компенсации внесенных каналом искажений отсутству-

ют, нейросеть напрямую формирует битовые решения, используя входные данные, полученные после БПФ в приемнике;

– приемник может работать не только с ФМ-, но и с КАМ-созвездиями;

– нейросеть состоит из двух блоков, один из которых специфичен для конкретной конфигурации пилот-сигналов, а второй – для конкретного вида модуляции, причем эти блоки могут использоваться в различных комбинациях;

– в отличие от публикаций, где нейросетевой приемник также разделен на блоки (например, [9]), для внутреннего сигнала на стыке упомянутых блоков нейросети нет конкретного обучающего образца – это некое промежуточное представление сигнала, формируемое самой нейросетью в процессе обучения;

– чтобы разработанный приемник мог использоваться в OFDM-системах с различным числом поднесущих, частотно-временной блок после дискретного преобразования Фурье в приемнике для подачи на вход нейросети разбивается на сравнительно узкополосные (возможно, перекрывающиеся) фрагменты, сдвиг по частоте между которыми кратен периоду структуры пилот-символов. Таким образом, приемник обрабатывает узкополосные фрагменты OFDM-сигнала отдельно, не полагаясь на пилот-символы, расположенные за пределами этих фрагментов. Это позволяет легко использовать такой приемник для обработки OFDM-сигналов с различной шириной спектра.

В данной статье развиваются идеи, исходно представленные в [13], где была предложена модульная структура OFDM-приемника и выполнено его обучение для одного конкретного вида модуляции (КАМ-16). В настоящей статье рассматриваются прежде всего особенности, связанные с построением гибко конфигурируемой модульной нейросети, позволяющей работать с разными видами модуляции.

Модель системы и классический подход к приему сигнала. Рассматривается OFDM-система с квадратурной модуляцией и частотно-селективным каналом с замираниями. Принятый сигнал в такой системе, после БПФ в приемнике, может быть описан следующей формулой:

$$Y_{n,k} = X_{n,k}H_{n,k} + W_{n,k}, \quad (1)$$

где $n = 1, \dots, N_T$ и $k = 1, \dots, N_{SC}$ – индексы времени и частоты соответственно (N_T и N_{SC} – количество OFDM-символов и количество поднесущих в анализируемом блоке соответственно); $X_{n,k}$, $H_{n,k}$, $W_{n,k}$ и $Y_{n,k}$ – переданное значение, коэффициент усиления канала связи, значение аддитивного белого гауссовского шума и принятое значение в частотно-временной позиции (n, k) соответственно.

В (1) предполагается, что длина циклического префикса в OFDM-сигнале не меньше, чем длина импульсной характеристики канала связи во временной области. Эта модель также предполагает, что состояние канала меняется медленно и его можно считать постоянным в пределах OFDM-символа.

Для некоторых частотно-временных позиций (n, k) передаваемые значения $X_{n,k}$ являются пилот-символами, известными на приемной стороне. Остальные позиции содержат неизвестные символы данных из используемого КАМ-созвездия.

Отношение сигнал/шум (Signal-to-Noise Ratio – SNR) определяется как отношение средних мощностей слагаемых, соответствующих полезному сигналу и шуму в (1):

$$\text{SNR} = \frac{\overline{|X_{n,k}H_{n,k}|^2}}{|W_{n,k}|^2},$$

где черта сверху – статистическое усреднение.

Классический подход к приему OFDM-сигналов состоит из трех этапов:

1. Исходя из известных значений пилот-символов вычисляются оценки CSI $\hat{H}_{n,k}$ для всех частотно-временных позиций (n, k) , содержащих символы данных.

2. Для символов данных компенсируются внесенные каналом связи искажения делением принятых значений $Y_{n,k}$ на полученные оценки CSI:

$$Z_{n,k} = \frac{Y_{n,k}}{\hat{H}_{n,k}} = X_{n,k} \frac{H_{n,k}}{\hat{H}_{n,k}} + \frac{W_{n,k}}{\hat{H}_{n,k}}.$$

3. Символы данных после компенсации ис-




Рис. 1. Классический подход к приему OFDM-сигнала

Fig. 1. Classical approach to OFDM reception

кажений ($Z_{n,k}$) демодулируются для получения жестких или мягких решений о значениях переданных битов.

Эта процедура схематично показана на рис. 1.

Входные данные для нейронной сети. Для рассматриваемого OFDM-приемника на основе нейронной сети входные данные формируются взятием небольшой части частотно-временной сетки $\{X_{n,k}\}$, содержащей как символы данных, так и пилот-символы, и разделением этих комплексных значений на вещественную и мнимую части. Используются прямоугольные фрагменты этой частотно-временной сетки, содержащие N_{SC} поднесущих и N_T OFDM-символов. Такой фрагмент содержит в общей сложности $N_{all} = N_{SC}N_T$ символов, среди которых N_P пилот-символов и $N_{all} - N_P$ символов данных. Все эти символы используются в качестве входных данных нейросети, чтобы облегчить оценку CSI и компенсацию искажений, но демодулируемая часть частотно-временной сетки меньше, она охватывает только N'_{SC} поднесущих и содержит N_d символов данных. На рис. 2 показана конфигурация входных данных, в дальнейшем используемая




Рис. 2. Входные данные для нейронной сети (пилот-символы обозначены буквой "P")

Fig. 2. Input data for the neural network (pilot symbols are labeled as "P")

для моделирования, где $N_{SC} = 8$, $N'_{SC} = 6$, $N_T = 14$, $N_{all} = 112$, $N_P = 8$ и $N_d = 80$. Такое расположение пилот-символов соответствует второму типу конфигурации опорных сигналов демодуляции (Demodulation Reference Signal – DM-RS) в физическом нисходящем общем канале (Physical Downlink Shared Channel – PDSCH) систем мобильной связи пятого поколения [2].

Целью включения дополнительных $N_{SC} - N'_{SC}$ поднесущих во входные данные нейросети является повышение качества оценки CSI за счет использования этой дополнительной информации.

Таким образом, входные данные являются трехмерным массивом с размерами, равными N_{SC} (поднесущие), N_T (OFDM-символы) и 2 (вещественная и мнимая составляющие).

Нелинейные преобразования чувствительны к уровню обрабатываемого сигнала. Чтобы нейронные сети могли работать в разнообразных условиях с различными мощностями сигнала и шума, входные блоки данных масштабируются таким образом, чтобы их средняя мощность в каждом блоке была равна единице:

$$Y'_{n,k} = \frac{Y_{n,k}}{\sqrt{P_{avg}}},$$

где

$$P_{avg} = \frac{1}{N_T N_{SC}} \sum_{n=1}^{N_T} \sum_{k=1}^{N_{SC}} |Y_{n,k}|^2. \quad (2)$$

Кроме того, поскольку пилот-символы в OFDM-системах обычно имеют псевдослучайные фазовые сдвиги, эти сдвиги перед подачей данных на вход нейросети следует компенсировать.

Архитектура нейронной сети. Соотношение "вход-выход" между принятым сигналом $X_{n,k}$ и решениями о значениях битов b_i представляет собой некоторую нелинейную функцию, которую можно реализовать с помощью универсального аппроксиматора в виде нейронной сети (рис. 3). Однако следует отметить, что различные архитектуры нейронных сетей могут обеспечивать различные компромиссы между качеством работы и сложностью.

Для изучения возможностей OFDM-приемников на основе нейронных сетей в преды-



Рис. 3. Прием OFDM-сигнала с помощью нейросети общего вида

Fig. 3. OFDM signal reception using a general neural network



Рис. 4. Прием OFDM-сигнала с помощью модульной нейросети

Fig. 4. OFDM signal reception using a modular neural network

дущей публикации авторов [13] было протестировано несколько архитектур. В результате была предложена структура, состоящая из двух отдельных нейросетей (рис. 4). Первая нейросеть получает на входе блок данных, описанный ранее (см. рис. 2), и формирует на своих выходах некое промежуточное представление символов данных. Таким образом, она неявно реализует оценку состояния канала связи, а также выполняет функции эквалайзера. Вторая нейросеть отвечает за демодуляцию данных. Она получает на входе промежуточное представление символов данных и формирует на своих выходах жесткие или мягкие решения о переданных битах.

Обучение двух нейросетей производится совместно, поэтому для промежуточного представления символов данных нет заданного образца. Таким образом, нейросеть сама формирует структуру этого представления в процессе обучения.

Модульная структура позволяет гибко конфигурировать OFDM-приемник, обучив несколько вариантов первой нейросети для разных конфигураций пилот-сигналов и несколько вариантов второй нейросети для разных видов модуляции.

Далее в [13] была конкретизирована структура двух нейросетей, что привело к получению структуры, показанной на рис. 5. Первая нейросеть представляет собой MLP с одним

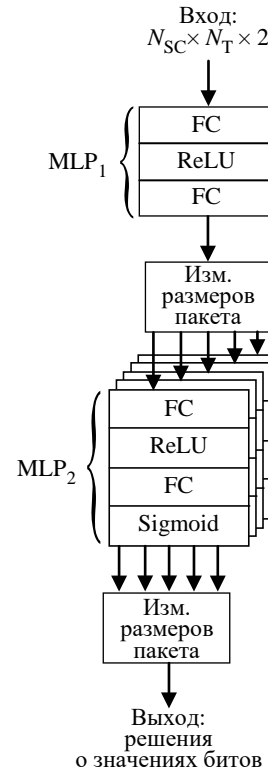


Рис. 5. Детализированная структура модульной нейросети

Fig. 5. Detailed structure of a modular neural network

скрытым слоем, т. е. комбинацию из двух полносвязных (Fully Connected – FC) слоев с нелинейной функцией активации между ними. В качестве этой функции использовался линейный выпрямитель (Rectified Linear Unit – ReLU). Следует отметить, что нелинейное преобразование на выходе этого модуля (на рис. 5 он обозначен как MLP₁) отсутствует.

Вторая нейросеть (MLP₂) состоит из N_d идентичных перцептронов, каждый из которых работает с промежуточным представлением одного символа данных. Чтобы реализовать обучение такой сети, в точке стыка первого и второго MLP изменяется размер пакета (batch) – один блок данных размером $N_d l$ (l – некоторое целое число, размерность промежуточного представления) превращается в N_d блоков размером l . На выходе сети производится обратное преобразование размера пакета – N_d блоков из m битовых решений преобразуются в один блок из $N_d m$ элементов. Сами перцептроны, как и MLP₁, имеют один скрытый слой с функцией активации ReLU. На выходе этих перцептронов для приведения результатов

к диапазону 0...1 используется сигмоидная функция активации. Далее приемник формирует жесткие решения о значениях принятых битов посредством округления.

Процедура обучения. Для обучения описанной сети была смоделирована OFDM-система со следующими параметрами:

- расстояние между поднесущими: 30 кГц;
- число поднесущих: 612 (51 блок ресурсов);
- число OFDM-символов в моделируемом блоке: 14;
- модуляция: КАМ-4 ($m=2$), КАМ-16 ($m=4$), КАМ-64 ($m=6$);
- модель канала: линия задержки с отводами (Tapped Delay Line – TDL) [14] с параметрами, выбираемыми случайным образом для каждого моделируемого блока:
 - профиль задержки: выбирается случайным образом из всех пяти профилей TDL (TDL-A, B, C, D, E);
 - разброс задержек: выбирается случайным образом из набора {30, 100, 300 нс} (согласно [14], это малый, номинальный и большой разброс соответственно);
 - доплеровский разброс: выбирается случайным образом из набора {5, 30, 70, 300 Гц} (это стандартные значения из [15]);
 - SNR: 20 дБ для модуляции КАМ-4, 30 дБ для модуляции КАМ-16, 40 дБ для модуляции КАМ-64.

Было смоделировано 1000 блоков (каждый блок охватывает 612 поднесущих и 14 OFDM-символов), и каждый блок был разделен на перекрывающиеся секции, показанные на рис. 2 (8 поднесущих \times 14 символов OFDM). В каждом блоке содержится 101 такая секция; таким образом, результирующий набор данных содержит 101 000 наблюдений.

Входные блоки были масштабированы в соответствии с (2). Кроме того, была реализована простая идеализированная временная синхронизация посредством вычисления взаимной корреляции между переданным и принятым сигналами, определения положения пика и соответствующего временного сдвига принятого сигнала.

Для обучения набора сетей были использованы следующие параметры процесса оптимизации:

- алгоритм оптимизации: Adam [16];

- скорость обучения: $3 \cdot 10^{-4}$;
- максимальное количество эпох: 200;
- размер пакета (N_{batch}): 2048 (это соответствует 49 пакетам на одну эпоху);
 - один пакет данных был использован для валидации, остальные наблюдения составили обучающий набор данных;
 - период валидации: 10 итераций (приблизительно 5 раз за эпоху);
 - критерий валидации: обучение прекращалось, если функция потерь для валидационного набора данных не уменьшалась в течение 10 валидаций;
 - для каждой эпохи обучающий набор данных перетасовывался.

В качестве критерия оптимизации была использована логистическая функция потерь (бинарная перекрестная энтропия):

$$L = \sum_{v=1}^{N_{\text{batch}}} \sum_{i=1}^{N_b} [b_{iv} \log(y_{iv}) + (1 - b_{iv}) \log(1 - y_{iv})],$$

где $N_b = N_d m$ – количество битов в одном обрабатываемом блоке; b_{iv} – истинное значение для i -го бита в v -м элементе пакета; y_{iv} – выход нейросети для того же элемента пакета.

Для тестирования полученных нейросетей были смоделированы зависимости частоты битовых ошибок (Bit Error Rate – BER) от SNR с использованием тех же параметров некодированной OFDM-системы и фиксированных наборов параметров канала TDL. Оценки BER усреднялись по 1000 блоков.

Определение гиперпараметров нейросетей. Для определения необходимых размеров слоев нейросетей было выполнено обучение нейросетей, подобных представленной на рис. 5, для конкретных видов модуляции. На этом этапе мерой качества приема служила частота битовых ошибок, полученная на валидационном наборе данных.

Для модуляции КАМ-16 (эти результаты были исходно представлены в [13]) были протестированы конфигурации со следующими значениями гиперпараметров:

- размер скрытого слоя MLP_1 : 1024, 2048, 4096;
- размер выхода MLP_1 : 160, 320, 640;




Рис. 6. Зависимость BER от размера скрытого слоя MLP₂ при разных гиперпараметрах MLP₁, модуляция KAM-16

Fig. 6. BER dependence on the MLP₂ hidden layer size for different neural hyperparameters of MLP₁, modulation 16QAM

– размер скрытого слоя MLP₂: степени двойки от 16 до размера скрытого слоя MLP₁.

На рис. 6 показаны зависимости качества работы сети (BER на валидационном наборе данных – BER_{valid}) от размера скрытого слоя MLP₂ при разных комбинациях размеров, относящихся к MLP₁ (эти комбинации размеров указаны в легенде графика).

При размере выхода MLP₁, равном 160, для каждого размера скрытого слоя MLP₁ на рис. 6 отображается только одна точка. Эта точка соответствует наибольшему размеру скрытого слоя MLP₂. Значения BER для этих сетей оказались настолько высоки, что тестировать меньшие размеры скрытого слоя MLP₂ было бесполезно. Эти результаты показывают, что размерность l промежуточных представлений символов данных, равная 2, является недостаточной.

Видно, что значения BER резко падают при увеличении размера скрытого слоя MLP₂ с 16 до 32. После этого значения BER уменьшаются еще немного и перестают меняться для размеров, превышающих 256.

Для размеров выхода MLP₁, равных 320 ($l = 4$) и 640 ($l = 8$), наименьшие достигнутые значения BER примерно одинаковы. Что касается влияния скрытого слоя MLP₁, то видно, что показатели BER постепенно улучшаются с увеличением его размера.

Анализ результатов для модуляции KAM-16 позволил выбрать размеры первых двух FC-

слоев, относящихся к персептрону MLP₁, который должен быть общим для приема всех видов модуляции:

- размер скрытого слоя MLP₁: 4096;
- размер выхода MLP₁: 320 ($l = 4$).

Кроме того, в результате анализа этих данных размер скрытого слоя MLP₂ для модуляции KAM-16 был выбран равным 256.

Обучение нейросетей для модуляции KAM-4 и KAM-64 производилось уже при фиксированных размерах слоев MLP₁, так что изменялись только размеры скрытого слоя MLP₂ в следующих пределах:

- для модуляции KAM-4: степени двойки от 8 до 1024;
- для модуляции KAM-64: степени двойки от 64 до 1024.

Результаты, аналогичные рис. 6, для этих видов модуляции показаны на рис. 7. Точки, соответствующие одному и тому же виду модуляции, соединены линиями.

Из графиков (рис. 7) видно, что для модуляции KAM-4 достаточным размером скрытого слоя MLP₂ является 32, а для KAM-64 – 256.

Итак, в результате анализа полученных зависимостей были выбраны следующие размеры слоев для нейросети, которая будет работать с разными видами модуляции:

- первый MLP: размер скрытого слоя – 4096, размер выходного слоя – 320 (четырёхмерное промежуточное представление для 80 символов данных);




Рис. 7. Зависимость BER от размера скрытого слоя MLP₂, модуляция KAM-4 и KAM-64

Fig. 7. BER dependence on the MLP₂ hidden layer size, modulation 4QAM and 64QAM

– второй MLP:
– входной размер – 4;
– размер скрытого слоя – 32 для КАМ-4; 256 для КАМ-16 и КАМ-64;
– размер выходного слоя равен числу битов в символе m (2, 4, 6 для КАМ-4; -16 и -64 соответственно).

Перцептрон MLP₁ с указанными размерами слоев имеет примерно 2.2 млн обучаемых параметров. Варианты перцептрона MLP₂ для модуляции КАМ-4; -16 и -64 имеют, соответственно, 226, 2308 и 2822 обучаемых параметров.

Следует, однако, отметить, что сложность данной нейросети, понимаемая в смысле числа обучаемых параметров, не отражает сложность OFDM-приемника, построенного на ее основе, поскольку в модуле MLP₂ N_d идентичных копий одного и того же перцептрона должны работать параллельно. Поэтому при расчете сложности именно приемника (в смысле числа операций N_{op} "умножение-накопление" (Multiply-Accumulate – MAC)) необходимо число обучаемых параметров перцептрона MLP₂ умножить на N_d . В результате сложность получившегося приемника для этих видов модуляции составляет приблизительно 2.25, 2.42 и 2.46 млн MAC-операций соответственно.

Обучение универсальной нейросети. Для реализации концепции, показанной на рис. 5, необходимо в результате обучения получить веса MLP₁, обеспечивающие формирование универсальных промежуточных представлений символов данных, пригодных для дальнейшей демодуляции разных видов модуляции. Для достижения этого обучение реализовано в двойном цикле – по порциям эпох и видам модуляции.

Внешний цикл – цикл по порциям обучения, каждая из которых содержала 5 эпох. Внутренний цикл – цикл по видам модуляции. Для каждого вида модуляции генерировался свой набор обучающих данных (его размер здесь был увеличен до 3000 блоков) и создавалась своя нейросеть. Чтобы обучать общий MLP₁ для всех видов модуляции, перед началом очередной порции обучения для очередной нейросети в нее загружались веса MLP₁, достигнутые при обучении предыдущей нейросети. После завершения порции обучения эти веса сохранялись для

дальнейшего использования в качестве начального состояния при обучении других нейросетей. Таким образом достигается оптимизация MLP₁, общего для всех нейросетей, предназначенных для приема разных видов модуляции.

После этого, в качестве финального этапа, для всех видов модуляции проводилось дообучение MLP₂ при "замороженных" весах MLP₁, достигнутых после завершения предыдущего этапа обучения и общих для всех нейросетей.

Зависимость BER от SNR. На рис. 8 показаны зависимости BER от SNR в OFDM-системе без помехоустойчивого кодирования для полученных нейронных сетей (в легенде графиков соответствующие кривые обозначены как "Network") в сравнительно благоприятных условиях канала: профиль задержек TDL-A, номинальный разброс задержек (100 нс), низкий доплеровский разброс (30 Гц). На этих графиках также показаны результаты для нескольких базовых алгоритмов:

– **"Perfect CSI"**: компенсация искажений, внесенных каналом связи, выполняется с использованием истинных значений CSI, извлеченных из модели канала;

– **"Practical CSI"**: компенсация искажений выполняется с помощью "практической оценки", реализованной в пакете расширения MATLAB, предназначенном для моделирования систем мобильной связи пятого поколения (5G Toolbox, функция `nrChannelEstimate` [17]). Здесь эта оценка применяется сразу ко всей полосе сигнала (612 поднесущих);

– **"Practical, blocks"**: та же "практическая" оценка, но примененная к входным блокам из 8 поднесущих (см. рис. 2) по отдельности.

Из графиков (рис. 8) видно, что для модуляции КАМ-4 и КАМ-16 нейросетевой приемник демонстрирует результаты, очень близкие к приемнику с "практической" оценкой CSI, выполненной с использованием всех пилот-символов одновременно (напомним, что рассматриваемая нейросеть для повышения универсальности работает с узкополосными фрагментами сигнала по отдельности). В случае модуляции КАМ-64 достигнутые результаты несколько хуже, но нейросетевой приемник все равно превосходит показатели традиционного приемника, использующего "практическую"




Рис. 8. Зависимость некодированного BER от SNR, канал TDL-A с разбросом задержки 100 нс и доплеровским разбросом 30 Гц при разных видах модуляции: а – KAM-4; б – KAM-16; в – KAM-64

Fig. 8. Uncoded BER vs. SNR, TDL-A channel with 100 ns delay spread and 30 Hz Doppler spread for different modulation: а – 4QAM; б – 16QAM; в – 64QAM




Рис. 9. Зависимость некодированного BER от SNR, канал TDL-C с разбросом задержки 300 нс и доплеровским разбросом 300 Гц при разных видах модуляции: а – KAM-4; б – KAM-16; в – KAM-64

Fig. 9. Uncoded BER vs. SNR, TDL-C channel with 300 ns delay spread and 300 Hz Doppler spread for different modulation: а – 4QAM; б – 16QAM; в – 64QAM

оценку, выполненную по тем же узкополосным блокам, с которыми работает нейросеть.

На рис. 9 показаны аналогичные результаты для более сложных свойств канала связи: про-

филь задержек TDL-C, большой разброс задержек (300 нс), высокий доплеровский разброс (300 Гц). Видно, что в этом случае все методы демонстрируют несократимую ошибку, но приемник на основе нейронной сети превосходит традиционный метод, заметно снижая это несократимое значение BER при использовании всех рассмотренных видов модуляции. Коэффициент снижения уровня несократимой ошибки по сравнению с традиционным приемником, использующим "практическую" оценку, выполняемую по всем пилот-символам блока, составляет:

- 6 для модуляции КАМ-4 (с $6 \cdot 10^{-3}$ до 10^{-3});
- 4 для модуляции КАМ-16 (с $1.6 \cdot 10^{-2}$ до $4 \cdot 10^{-3}$);
- 2.3 для модуляции КАМ-64 (с $3.2 \cdot 10^{-2}$ до $1.4 \cdot 10^{-2}$).

Заключение. В статье была предложена структура нейросетевого приемника OFDM-сигналов, основанного на комбинации двух многослойных перцептронов. Первый из них в неявной форме выполняет оценку CSI и компенсацию искажений, а второй реализует демодуляцию символов данных.

Полученные результаты можно кратко сформулировать следующим образом:

– анализ влияния гиперпараметров на качество работы показал, что для промежуточного внутреннего представления символов данных требуется размерность, превышающая минимально необходимую: использование четырехмерных представлений вместо минимально необходимых двумерных позволило снизить частоту ошибок в 8–15 раз (см. рис. 6);

– оптимизированная сеть для всех рассмотренных видов модуляции продемонстрировала хорошие показатели BER при некодированной передаче, сравнимые с базовыми показателями, при благоприятных условиях канала (умеренный разброс задержек при низком доплеровском разбросе) и превзошла базовые показатели в тяжелых условиях (канал с большим разбросом задержек и высоким доплеровским разбросом). Коэффициент снижения несократимой частоты ошибок в последнем случае составил от 2.3 до 6 раз.

Возможные направления дальнейших исследований:

– применение аналогичного подхода при формировании мягких решений для переданных битов;

– явная реализация внутри обучаемой сети таких конкретных математических операций, как комплекснозначное деление, для облегчения аппроксимации процедур, подобных компенсации канальных искажений.

Список литературы

1. LTE; Evolved Universal Terrestrial Radio Access (E-UTRA); Physical channels and modulation (3GPP TS 36.211 version 18.0.1 Release 18). ETSI, 2024. URL: https://www.etsi.org/deliver/etsi_ts/136200_136299/136211/18.00.01_60/ts_136211v180001p.pdf (дата обращения 09.06.2025).
2. 5G; NR; Physical channels and modulation (3GPP TS 38.211 version 18.2.0 Release 18). ETSI, 2024. URL: https://www.etsi.org/deliver/etsi_ts/138200_138299/138211/18.02.00_60/ts_138211v180200p.pdf (дата обращения 09.06.2025).
3. 6G RAN – key building blocks for new 6G radio access networks. URL: <https://www.ericsson.com/en/blog/2024/5/future-6g-radio-access-network-design-choices> (дата обращения 04.12.2024).
4. Deep learning-based channel estimation / M. Soltani, V. Pourahmadi, A. Mirzaei, H. Sheikhzadeh // IEEE Communications Let. 2019. Vol. 23, № 4. P. 652–655. doi: 10.1109/LCOMM.2019.2898944

5. Luan D., Thompson J. Low complexity channel estimation with neural network solutions // 25th Intern. ITG Workshop on Smart Antennas, French Riviera, France, 10–

- 12 Nov. 2021. IEEE, 2021. P. 1–6.

6. Zhao S., Fang Y., Qiu L. Deep learning-based channel estimation with SRGAN in OFDM systems // IEEE Wireless Communications and Networking Conf. (WCNC), Nanjing, China, 29 March–01 Apr. 2021. IEEE, 2021. P. 1–6. doi: 10.1109/WCNC49053.2021.9417242

7. Deep learning channel estimation for OFDM 5G systems with different channel models / A. S. M. Mohammed, A. I. A. Taman, A. M. Hassan, A. Zekry // Wireless Personal Communications. 2023. Vol. 128, № 4. P. 2891–2912. doi: 10.1007/s11277-022-10077-6

8. Peng Q., Li J., Shi H. Deep learning based channel estimation for OFDM systems with doubly selective channel // IEEE Communications Let. 2022. Vol. 26, № 9. P. 2067–2071. doi: 10.1109/LCOMM.2022.3187161

9. Neural network-based OFDM receiver for resource constrained IoT devices / N. Soltani, H. Cheng, M. Belgiovine, Y. Li, H. Li, B. Azari, S. D'Oro, T. Imbiriba, T. Melodia, P. Closas, Y. Wang, D. Erdogmus, K. Chowdhury // IEEE Internet of Things Magazine.

2022. Vol. 5, № 3. P. 158–164.

doi: 10.1109/IOTM.001.2200051

10. Ye H., Li G. Y., Juang B.-H. Power of deep learning for channel estimation and signal detection in OFDM systems // IEEE Wireless Communications Let. 2018. Vol. 7, № 1. P. 114–117.

doi: 10.1109/LWC.2017.2757490

11. Adaptive neural network-based OFDM receivers / M. B. Fischer, S. Dörner, S. Cammerer, T. Shimizu, H. Lu, S. T. Brink // IEEE 23rd Intern. Workshop on Signal Processing Advances in Wireless Communication (SPAWC). 2022. P. 1–5.

doi: 10.1109/SPAWC51304.2022.9833970

12. A signal processing method of OFDM communication receiver based on CNN / B. Wang, H. Dai, K. Xu, Y. Sun, Y. Zhang, P. Li // Physical Communication. 2023. Vol. 59. Art. № 102055.

doi: 10.1016/j.phycom.2023.102055

13. Sergienko A. B., Apalina P. V., Lebedinskaya A. D. Reception of OFDM signals in narrow subbands by a neural network-based receiver with batch reshape // IEEE 3rd Intern. Conf. on Problems of Informatics,

Electronics and Radio Engineering (PIERE), Novosibirsk, 15–17 Nov. 2024. IEEE, 2024. P. 70–75.

doi: 10.1109/PIERE62470.2024.10804946

14. 5G; Study on channel model for frequencies from 0.5 to 100 GHz (3GPP TR 38.901 version 16.1.0 Release 16). ETSI, 2020. URL: https://www.etsi.org/deliver/etsi_tr/138900_138999/138901/16.01.00_60/tr_138901v160100p.pdf (дата обращения 09.06.2025).

15. LTE; Evolved Universal Terrestrial Radio Access (E-UTRA); User Equipment (UE) radio transmission and reception (3GPP TS 36.101 version 17.12.0 Release 17). ETSI, 2024. URL: https://www.etsi.org/deliver/etsi_ts/136100_136199/136101/17.12.00_60/ts_136101v171200p.pdf (дата обращения 09.06.2025).

16. Kingma D. P., Ba J. Adam: A method for stochastic optimization // Intern. Conf. on Learning Representations (ICLR). 2015. P. 1–15.

doi: 10.48550/arXiv.1412.6980

17. MATLAB 5G Toolbox, Documentation for nrChannelEstimate function. URL: <https://www.mathworks.com/help/5g/ref/nrchannelestimate.html> (дата обращения 04.12.2024).

Информация об авторах

Сергиенко Александр Борисович – кандидат технических наук (1995), доцент (1998), профессор кафедры теоретических основ радиотехники Санкт-Петербургского государственного электротехнического университета "ЛЭТИ" им. В. И. Ульянова (Ленина). Автор более 140 научных работ. Сфера научных интересов – обработка сигналов в системах цифровой связи.

Адрес: Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина), ул. Профессора Попова, д. 5 Ф, Санкт-Петербург, 197022, Россия

E-mail: absergienko@etu.ru

<https://orcid.org/0000-0003-0968-9708>

Апалина Полина Владимировна – магистр по направлению "Радиотехника" (2022, Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина)), аспирантка кафедры теоретических основ радиотехники Санкт-Петербургского государственного электротехнического университета "ЛЭТИ" им. В. И. Ульянова (Ленина). Автор 11 научных работ. Сфера научных интересов – сигнально-кодовые конструкции для некогерентного приема.

Адрес: Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина), ул. Профессора Попова, д. 5 Ф, Санкт-Петербург, 197022, Россия

E-mail: pvapalina@etu.ru

<https://orcid.org/0000-0002-5636-8344>

Лебединская Анастасия Дмитриевна – магистр по направлению "Радиотехника" (2023, Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина)), аспирантка кафедры теоретических основ радиотехники Санкт-Петербургского государственного электротехнического университета "ЛЭТИ" им. В. И. Ульянова (Ленина). Автор двух научных публикаций. Сфера научных интересов – рандомизированные алгоритмы декодирования помехоустойчивых кодов.

Адрес: Санкт-Петербургский государственный электротехнический университет "ЛЭТИ" им. В. И. Ульянова (Ленина), ул. Профессора Попова, д. 5 Ф, Санкт-Петербург, 197022, Россия

E-mail: lad6575@mail.ru

<https://orcid.org/0009-0004-3644-8306>

References

1. LTE; Evolved Universal Terrestrial Radio Access (E-UTRA); Physical channels and modulation (3GPP TS 36.211 version 18.0.1 Release 18). ETSI, 2024. Available at: https://www.etsi.org/deliver/etsi_ts/136200_136299/136211/18.00.01_60/ts_136211v180001p.pdf (accessed 09.06.2025).

2. 5G; NR; Physical channels and modulation (3GPP TS 38.211 version 18.2.0 Release 18). ETSI, 2024. Available at: https://www.etsi.org/deliver/etsi_ts/138200_138299/138211/18.02.00_60/ts_138211v180200p.pdf (accessed 09.06.2025).

3. 6G RAN – key building blocks for new 6G radio access networks. Available at: <https://www.ericsson.com/en/blog/2024/5/future-6g-radio-access-network-design-choices> (accessed 04.12.2024).
4. Soltani M., Pourahmadi V., Mirzaei A., Sheikhzadeh H. Deep Learning-Based Channel Estimation. *IEEE Communications Let.* 2019, vol. 23, no. 4, pp. 652–655. doi: 10.1109/LCOMM.2019.2898944
5. Luan D., Thompson J. Low Complexity Channel Estimation with Neural Network Solutions. 25th Intern. ITG Workshop on Smart Antennas, French Riviera, France, 10–12 Nov. 2021. *IEEE*, 2021, pp. 1–6.
6. Zhao S., Fang Y., Qiu L. Deep Learning-Based Channel Estimation with SRGAN in OFDM Systems. *IEEE Wireless Communications and Networking Conf. (WCNC)*, Nanjing, China, 29 March–01 Apr. 2021. *IEEE*, 2021, pp. 1–6. doi: 10.1109/WCNC49053.2021.9417242
7. Mohammed A. S. M., Taman A. I. A., Hassan A. M., Zekry A. Deep Learning Channel Estimation for OFDM 5G Systems with Different Channel Models. *Wireless Personal Communications*. 2023, vol. 128, no. 4, pp. 2891–2912. doi: 10.1007/s11277-022-10077-6
8. Peng Q., Li J., Shi H. Deep Learning Based Channel Estimation for OFDM Systems with Doubly Selective Channel. *IEEE Communications Let.* 2022, vol. 26, no. 9, pp. 2067–2071. doi: 10.1109/LCOMM.2022.3187161
9. Soltani N., Cheng H., Belgiovine M., Li Y., Li H., Azari B., D'Oro S., Imbiriba T., Melodia T., Closas P., Wang Y., Erdogmus D., Chowdhury K. Neural Network-Based OFDM Receiver for Resource Constrained IoT Devices. *IEEE Internet of Things Magazine*. 2022, vol. 5, no. 3, pp. 158–164. doi: 10.1109/IOTM.001.2200051
10. Ye H., Li G. Y., Juang B.-H. Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems. *IEEE Wireless Communications Let.* 2018, vol. 7, no. 1, pp. 114–117. doi: 10.1109/LWC.2017.2757490
11. Fischer M. B., Dörner S., Cammerer S., Shimizu T., Lu H., Brink S. T. Adaptive Neural Network-Based OFDM Receivers. *IEEE 23rd Intern. Workshop on Signal Processing Advances in Wireless Communication (SPAWC)*. 2022, pp. 1–5. doi: 10.1109/SPAWC51304.2022.9833970
12. Wang B., Dai H., Xu K., Sun Y., Zhang Y., Li P. A Signal Processing Method of OFDM Communication Receiver Based on CNN. *Physical Communication*. 2023, vol. 59, art. no. 102055. doi: 10.1016/j.phycom.2023.102055
13. Sergienko A. B., Apalina P. V., Lebedinskaya A. D. Reception of OFDM Signals in Narrow Subbands by a Neural Network-Based Receiver with Batch Reshape. *IEEE 3rd Intern. Conf. on Problems of Informatics, Electronics and Radio Engineering (PIERE)*, Novosibirsk, 15–17 Nov. 2024. *IEEE*, 2024, pp. 70–75. doi: 10.1109/PIERE62470.2024.10804946
14. 5G; Study on channel model for frequencies from 0.5 to 100 GHz (3GPP TR 38.901 version 16.1.0 Release 16). ETSI, 2020. Available at: https://www.etsi.org/deliver/etsi_tr/138900_138999/138901/16.01.00_60/tr_138901v160100p.pdf (accessed 09.06.2025).
15. LTE; Evolved Universal Terrestrial Radio Access (E-UTRA); User Equipment (UE) radio transmission and reception (3GPP TS 36.101 version 17.12.0 Release 17). ETSI, 2024. Available at: https://www.etsi.org/deliver/etsi_ts/136100_136199/136101/17.12.00_60/ts_136101v171200p.pdf (accessed 09.06.2025).
16. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. *Intern. Conf. on Learning Representations (ICLR)*. 2015, pp. 1–15. doi: 10.48550/arXiv.1412.6980
17. MATLAB 5G Toolbox, Documentation for nrChannelEstimate function. Available at: <https://www.mathworks.com/help/5g/ref/nrchannelestimate.html> (accessed 04.12.2024).

Information about the authors

Alexander B. Sergienko, Cand. Sci. (Eng.) (1995), Associate Professor (1998), Professor of the Department of Theoretical Fundamentals of Radio Engineering of Saint Petersburg Electrotechnical University. The author of more than 140 scientific publications. Area of expertise: signal processing in digital communications.

Address: Saint Petersburg Electrotechnical University, 5 F, Professor Popov St., St Petersburg 197022, Russia

E-mail: absergienko@etu.ru

<https://orcid.org/0000-0003-0968-9708>

Polina V. Apalina, Master's degree in Radio Engineering (2022, Saint Petersburg Electrotechnical University), Postgraduate student of the Department of Theoretical Fundamentals of Radio Engineering of Saint Petersburg Electrotechnical University. The author of 11 scientific publications. Area of expertise: coded modulation for noncoherent reception.

Address: Saint Petersburg Electrotechnical University, 5 F, Professor Popov St., St Petersburg 197022, Russia

E-mail: pvapalina@etu.ru

<https://orcid.org/0000-0002-5636-8344>

Anastasia D. Lebedinskaya, Master's degree in Radio Engineering (2023, Saint Petersburg Electrotechnical University), Postgraduate student of the Department of Theoretical Fundamentals of Radio Engineering of Saint Petersburg Electrotechnical University. The author of 2 scientific publications. Area of expertise: randomized algorithms for decoding of error-correcting codes.

Address: Saint Petersburg Electrotechnical University, 5 F, Professor Popov St., St Petersburg 197022, Russia

E-mail: lad6575@mail.ru

<https://orcid.org/0009-0004-3644-8306>