

СНИЖЕНИЕ ПИК-ФАКТОРА ПРИ НЕРАВНОМЕРНОМ РАСПРЕДЕЛЕНИИ РЕСУРСОВ В СИСТЕМАХ СВЯЗИ С БОЛЬШИМ ЧИСЛОМ АБОНЕНТОВ

DOI: 10.36724/2072-8735-2026-20-4-4-11

Manuscript received 22 January 2026;
Accepted 28 March 2026**Крикунов Станислав Александрович,**

Автономная некоммерческая образовательная организация
высшего образования "Сколковский институт науки и
технологий", Москва, Россия,
stanislav.krikunov@skoltech.ru

Иванов Андрей Андреевич,

Автономная некоммерческая образовательная организация
высшего образования "Сколковский институт науки и
технологий", Москва, Россия,
an.ivanov@skoltech.ru

Ключевые слова: Пик-фактор,
мультиплексирование с ортогональным частотным
разделением каналов, машинное обучение,
кластеризация, регрессия

Статья посвящена методу снижения пик-фактора в нисходящей линии систем связи при неоднородном распределении ресурсов между абонентами. В режиме с большим числом абонентов допустимая величина вектора ошибки (Error Vector Magnitude, EVM) становится переменной и изменяется при вариациях выделенных ресурсов: полосы пропускания, порядка модуляции и излучаемой мощности. Это затрудняет снижение пик-фактора известными методами, такими как клиппирование и фильтрация, поскольку требуемое число итераций и параметры метода зависят от текущей конфигурации абонентов и распределения ресурсов. Оптимальный сигнал подавления пиков может быть сформирован строго в соответствии с ограничениями по EVM с помощью метода резервирования тонов, однако на практике это требует подбора гиперпараметров путём полного перебора, что не может быть осуществлено в режиме реального времени. В работе предлагается метод, обеспечивающий квази-оптимальное подавление пиков без дорогостоящего перебора гиперпараметров онлайн. Он включает комбинаторную кластеризацию абонентов по допустимой EVM с учётом выделенных ресурсов и резервирование тонов с предсказанием порога отбора пиков малопараметрическими моделями. Обучение выполняется офлайн на наборе случайных сценариев. Моделирование демонстрирует близкое к оптимальному подавление пиков: разница между полученным пик-фактором и достижимой границей составляет менее 0,5 дБ. Также продемонстрирована высокая корреляция между предсказанными и найденными полным перебором порогами, что подтверждает состоятельность модели. Для практической реализации рекомендуется использовать линейную регрессию и ограниченное число групп. Подход применим в системах 5G.

Информация об авторах:

Крикунов Станислав Александрович, аспирант Сколковского института и технологий, Москва, Россия. ORCID 0009-0001-9775-3564
Иванов Андрей Андреевич, к.т.н, профессор Сколковского института и технологий, Москва, Россия. ORCID 0000-0001-9107-3368

Для цитирования:

Крикунов С. А., Иванов А. А. Снижение пик-фактора при неравномерном распределении ресурсов в системах связи с большим числом абонентов // Т-Сотм: Телекоммуникации и транспорт. 2026. Том 20. №4. С. 4-11.

For citation:

S. A. Krikunov, A. A. Ivanov, "PAPR Reduction in Multi-User FDD-OFDM Systems Under Non-Uniform Resource Allocation," *T-Comm*, 2026, vol. 20, no. 4, pp. 4-11. (in Russian)

Введение

Мультиплексирование с ортогональным частотным разделением каналов (Orthogonal Frequency Division Multiplexing, OFDM) – техника многочастотной модуляции, лежащая в основе беспроводных систем связи, таких как 5G [1]. OFDM широко используется в нисходящем канале беспроводных систем связи [2]. OFDM-сигнал имеет высокий пик-фактор (Peak-to-Average Power Ratio, PAPR), который определяется как отношение пиковой мощности отсчёта сигнала к средней мощности всех отсчётов OFDM-символа:

$$PAPR(x) = 10 \lg \frac{\max(|x(n)|^2)}{\mathbb{E}[|x(n)|^2]}, \quad (1)$$

где $x(n) \in \mathbb{C}^{N_{FFT} \times 1}$ – OFDM-символ во временной области, $n \in [0 \dots N_{FFT} - 1]$ – индекс его отсчёта, $\max(\cdot)$ – операция нахождения максимального значения, $\mathbb{E}[\cdot]$ – оператор математического ожидания, N_{FFT} – размер быстрого преобразования Фурье (Fast Fourier Transform, FFT, БПФ).

Высокий пик-фактор приводит к нелинейному режиму работы усилителя высокой мощности. В результате, усилитель генерирует нелинейные искажения в дополнение к усиленному входному сигналу. Поэтому необходим эффективный подход к снижению пик-фактора. Кроме того, высокое значение пик-фактора может требовать использования цифро-аналоговых преобразователей с более высоким разрешением на стороне передатчика [3].

1 Обзор литературы

Рассмотрим методы снижения пик-фактора, совместимые со стандартом 5G и оценим их работоспособность в сценариях, когда каждый OFDM-символ содержит сигналы нескольких абонентов. Абоненты находятся в различных условиях распространения сигнала, поэтому в нисходящем канале связи им выделяются разные ресурсы: порядки модуляции, полосы пропускания и мощности излучения.

Наиболее простой и распространённый способ снижения пик-фактора – клиппирование с последующей фильтрацией. Нелинейность клиппирования вызывает внутрисполосные и внеполосные искажения, называемые шумом клиппирования [4, 5]. Внеполосные компоненты подавляются фильтрацией, однако это приводит к восстановлению пиков. При смешанных порядках модуляции абонентов в спектре OFDM-сигнала эффективность метода ограничена единым порогом клиппирования, который задаётся минимально допустимой величиной вектора ошибки (Error Vector Magnitude, EVM) среди всех абонентов в спектре сигнала. Внутрисполосные компоненты имеют близкий к равномерному спектр, поэтому ограничения по значению EVM обусловлены абонентами с максимальным порядком модуляции [6]. Для поднесущих с меньшими порядками модуляции допустимо большее значение EVM, но снижение порога клиппирования ограничено требованиями наиболее «чувствительных» поднесущих, то есть абонентов с наивысшим порядком модуляции. Следовательно, клиппирование и фильтрация не используют частотное распределение допустимого значения EVM и потому оказываются неэффективными.

Другой метод основан на резервировании тонов [7, 8]. Он применяет итеративное вычисление амплитуд для построения сигнала подавления пиков из набора зарезервированных

поднесущих частот. Однако, вычислительная сложность метода слишком высока [9]. Данной проблеме не подвержен итеративный алгоритм выборочного резервирования тонов (Selective Tone Reservation, STR) [10], основанный на вычислении минимальной среднеквадратической ошибки. Эффективность алгоритма приближается к пределу, определяемому заданными ограничениями на значение EVM.

Были предложены способы усовершенствования метода резервирования тонов при помощи глубокого обучения [11], [12]. Каждая итерация уменьшения пик-фактора разворачивается в слой глубокой нейронной сети, порог клиппирования выбирается на каждой итерации отдельно. Этот метод превосходит стандартный метод резервирования тонов и имеет сопоставимую сложность.

Другой класс методов, предложенный для многоантенных систем, использует свободные пространственные направления для распределения сигнала подавления пиков. В алгоритме [13] резервирование лучей происходит путем пространственного разделения сигналов абонентов и сигнала подавления пиков. Снижение пик-фактора происходит на каждой передающей антенне. Метод обеспечивает низкую вычислительную задержку и совместим со стандартом 5G.

В работах [14-16] предложены методы снижения пик-фактора, основанные на нейросетях, в том числе, автокодировщиках. Отображение символов данных в сигнальное созвездие и обратная операция выполняются адаптивно с использованием нейросети и многокритериальной оптимизации: снижение пик-фактора и вероятности битовых ошибок происходят одновременно. Автокодировщики обеспечивают более высокие показатели качества относительно традиционных подходов, однако они несовместимы с действующими стандартами связи.

Были предложены и другие методы машинного обучения, например, алгоритм, поддерживающий выборочное резервирование тонов и лучей одновременно [17]. В данной работе полный перебор гиперпараметров заменен стандартными алгоритмами машинного обучения для аппроксимации с низкой вычислительной сложностью. В результате, поиск наилучших гиперпараметров может происходить в режиме реального времени, что подходит для системы связи 5G. В работе предполагается одинаковая спектральная плотность мощности излучения для всех абонентов, что на практике выполняется редко. Таким образом, распределение допустимых значений EVM в полосе используется без учёта излучаемой мощности абонентов, что приводит к завышенному пик-фактору.

2 Вклад авторов

В отличие от существующих алгоритмов [17], в данной работе предусмотрено неравномерное распределение ресурсов, выделяемых в нисходящем канале связи каждому из абонентов системы: мощности передачи, полосы пропускания и порядка модуляции.

В статье предлагается новый алгоритм кластеризации абонентов для повышения эффективности применения алгоритма снижения пик-фактора при фиксированном числе итераций. Алгоритм кластеризации построен на основе решения комбинаторной задачи оптимизации целевой функции. В качестве алгоритма снижения пик-фактора используется алгоритм STR, для которого в работе определяются квазиоптимальные гиперпараметры путем предсказания с помощью

алгоритмов машинного обучения. Многомерная аппроксимация строится на базе значений, найденных методом полного перебора на случайном наборе сценариев распределения ресурсов.

Для оценки эффективности предложенного подхода кластеризации и предсказания гиперпараметров было проведено моделирование случайной выборки сценариев и, для некоторых из них, выполнено сравнение с базовым методом снижения пик-фактора – клиппированием и фильтрацией.

3 Алгоритм выборочного резервирования тонов

Алгоритм STR основан на отборе наиболее мощных пиков в рамках каждого OFDM-символа и последующей генерации сигнала их компенсации из набора поднесущих. В алгоритме применяется ограничение максимального уровня сигнала подавления пиков согласно допустимому значению EVM.

Сначала к абсолютным значениям начального сигнала x во временной области применяется пороговая обработка:

$$y = x(n), \text{ если } |x(n)| \geq \tau, \text{ иначе } 0, \quad (2)$$

где $y \in \mathbb{C}^{N_{FFT} \times 1}$ – вектор, состоящий из нежелательных пиков вектора x , порог τ – порог отбора пиков, предсказываемый гиперпараметр. Вектор комплексного сигнала с уменьшенным пик-фактором $z \in \mathbb{C}^{N_{FFT} \times 1}$ вычисляется следующим образом:

$$z = x - Sa, \quad (3)$$

где $S \in \mathbb{C}^{N_{FFT} \times N_{SC}}$ – часть матрицы Фурье, состоящая из N_{SC} выбранных поднесущих $e^{\frac{2\pi\sqrt{-1}mn}{N_{FFT}}}$ с амплитудами $a \in \mathbb{C}^{N_{SC} \times 1}$, где $m \in [0 \dots N_{SC} - 1]$ – индексы выбранных поднесущих. Произведение Sa представляет собой сигнал подавления пиков. Амплитуды вектора a вычисляются следующим образом:

$$a = \underset{G \in \Omega}{\operatorname{argmin}} \|y - Sa\|_2^2 = \frac{1}{N_{FFT}} S^H y, \quad (4)$$

где H – операция Эрмитова сопряжения.

Алгоритм STR выполняется итеративно за N_G шагов:

Шаг 1:

1) вычисление порога τ (может быть одинаковым для каждой итерации без потерь в качестве подавления пиков);

Шаги $i, i \in [1 \dots N_G]$:

2) построение матрицы Фурье, используя выбранные поднесущие i -й группы абонентов;

4) поиск пиков, превышающих порог, используя (2);

5) вычисление сигнала подавления пиков (4);

6) уменьшение пиков сигнала в соответствии с (3);

7) оценка п-фактора согласно (1).

4 Алгоритм кластеризации абонентов

Алгоритм кластеризации абонентов предполагает фиксированное число итераций снижения пик-фактора согласно числу групп абонентов, так как в аппаратной реализации это число должно быть постоянным. Это необходимо, чтобы избежать увеличения задержки в разных сценариях [8]. Проблема кластеризации возникает, когда количество абонентов в спектре превышает заданное количество итераций снижения пик-фактора. Работа алгоритма кластеризации абонентов

совместно с алгоритмом STR показана на рисунке 1. Блок кластеризации использует максимально допустимые значения EVM, относительные выделенные мощности и частотные ресурсы. Найденное разбиение на группы используется в итеративном алгоритме STR, осуществляемом для каждой из групп абонентов.

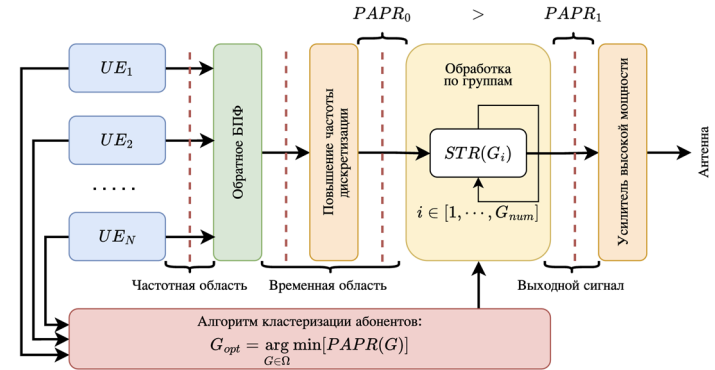


Рис. 1. Схема алгоритма снижения пик-фактора

Пусть абоненту выделено некоторое число частотных ресурсных элементов, каждый из которых называется ресурсным блоком (Resource Block, RB). Введём обозначение: P – нормированная мощность абонента. Максимально допустимое значение EVM абонента определяется порядком модуляции. Введём допустимую величину сигнала подавления пиков (Allowed Noise Level, ANL). Название ANL обусловлено тем, что сигнала подавления пиков может быть интерпретирован как нелинейный шум. Таким образом, ANL каждого абонента в рамках выделенных частотных ресурсов:

$$ANL(P, EVM) = P \cdot EVM^2. \quad (5)$$

Абоненты с близкими допустимыми величинами сигнала подавления пиков распределяются в одну и ту же группу. Самый простой метод кластеризации заключается в максимизации суммарной мощности сигнала подавления пиков по всем абонентам:

$$P_{COMP} = \sum_{i=1}^{N_G} N_{RB}(i) ANL_{min}(i), \quad (6)$$

где P_{COMP} – мощность сигнала подавления пиков, ANL_{min} – максимально допустимая величина сигнала подавления пиков в группе абонентов; N_{RB} – количество общих частотных ресурсов в рамках группы абонентов. N_G – число групп абонентов, i – индекс группы абонентов. Каждая группа включает не менее 1 абонента.

4.1 Получение зависимостей

Для установления зависимости между допустимым значением сигнала подавления пиков (5) и эффективностью снижения пик-фактора методом STR (4), был проведён эксперимент. В ходе эксперимента число ресурсных блоков, используемых для снижения пик-фактора, варьировалось от 1 до N_{RB} , а величина сигнала подавления пиков (5) варьировалась в рамках стандартных значений для соответствующих порядков модуляций: от ANL для мощности 1% и $EVM_{QAM1024} = 2,5\%$ до ANL для мощности 99% и $EVM_{QPSK} = 17,5\%$. Результаты эксперимента представлены на рисунках 2 и 3. Вклад ширины выделенной полосы пропускания близок к

линейному, тогда как увеличение допустимого уровня сигнала подавления пиков может быть аппроксимировано функцией квадратного корня. Поэтому, предлагается определять вклад величины ANL и N_{RB} i -й группы абонентов следующим образом:

$$C(i) = N_{RB}(i)\sqrt{ANL_{min}(i)}. \quad (7)$$

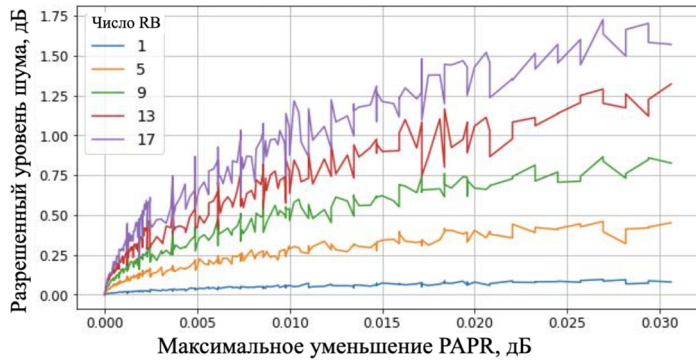


Рис. 2. Влияние значения ANL на снижение пик-фактора для алгоритма STR (срезы по различному числу RB)

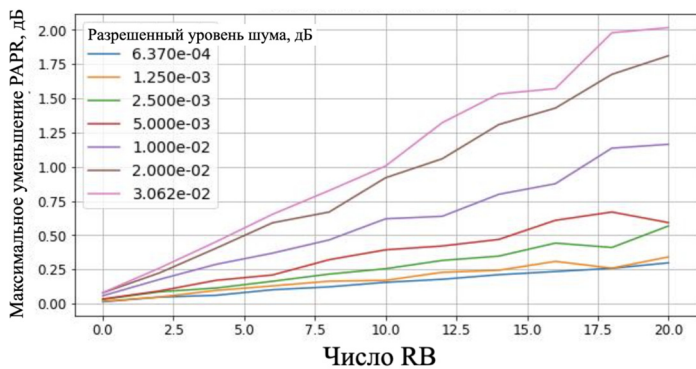


Рис. 3. Влияние числа RB на снижение пик-фактора для алгоритма STR (срезы по значению ANL)

4.2 Критерий кластеризации абонентов

Рассмотрим алгоритм кластеризации, основанный на комбинаторной оптимизации. Задача состоит в нахождении разбиения абонентов, которое минимизирует значение пик-фактора после подавления пиков во всех группах. Поиск происходит среди всех возможных разбиений:

$$G_{opt} = \underset{G \in \Omega}{\operatorname{argmin}} PAPR(G), \quad (8)$$

где Ω – множество всех возможных разбиений пользователей на группы, G – произвольное разбиение на группы, G_{opt} – оптимальное (целевое) разбиение на группы.

Алгоритм вычисляет потенциальный вклад каждой группы в снижение пик-фактора с использованием (7). Применяя данный подход и предположив его независимость от номера итерации, можно построить целевую функцию общего вклада:

$$F(G) = \sum_{i=1}^{N_G} C(i). \quad (9)$$

Минимизация данной целевой функции позволяет найти оптимальное разбиение абонентов на группы (8).

4.3 Пошаговый алгоритм кластеризации

Алгоритм кластеризации, проиллюстрированный на рисунке 4, выполняется в несколько этапов:

- 1) Сортировка абонентов согласно допустимой величине сигнала подавления пиков;
- 2) Генерация всех возможных разбиений абонентов на группы, как показано в таблице 1. Генерация – комбинаторная задача разбиения упорядоченного множества на непересекающиеся подмножества;
- 3) Вычисление потенциального вклада для каждого разбиения абонентов на группы с использованием (9);
- 4) Выбор разбиения, соответствующего максимальному вкладу в снижение пик-фактора согласно (10):

$$G_{opt} = \underset{G \in \Omega}{\operatorname{argmax}} F(G). \quad (10)$$

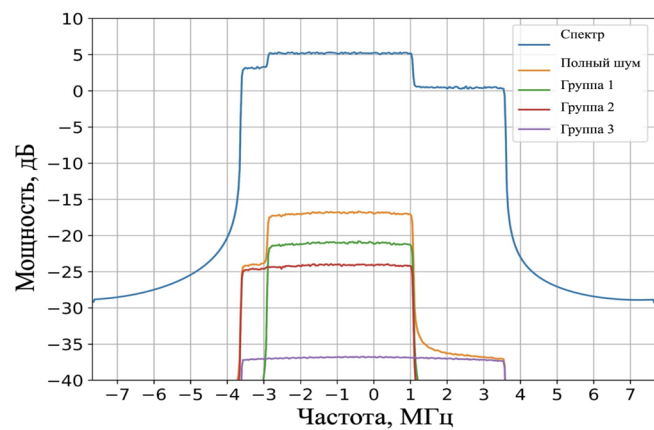


Рис. 4. Последовательное снижение пик-фактора в каждой из групп

Таблица 1

Все варианты распределения 5 абонентов в 2 или 3 группы

	2 группы ([G1], [G2])	3 группы ([G1], [G2], [G3])
1	[1], [2, 3, 4, 5]	[1], [2], [3, 4, 5]
2	[1, 2], [3, 4, 5]	[1], [2, 3], [4, 5]
3	[1, 2, 3], [4, 5]	[1], [2, 3, 4], [5]
4	[1, 2, 3, 4], [5]	[1, 2], [3], [4, 5]
5		[1, 2], [3, 4], [5]
6		[1, 2, 3], [4], [5]

5 Выбор порогового значения

Оптимальное пороговое значение τ_{opt} , обеспечивающее максимальное снижение пик-фактора, определяется согласно (11) следующим образом:

$$\tau_{opt} = \underset{\tau}{\operatorname{argmin}} PAPR(STR(x, \tau)), \quad (11)$$

где $\tau = \tau(N_{RB}, ANL)$ – функция, зависящая от векторов $N_{RB} = [N_{RB}(1), \dots, N_{RB}(N_G)]$ (распределение частотных ресурсов для каждой группы) и $ANL = [ANL(1), \dots, ANL(N_G)]$ (максимально допустимый уровень сигнала подавления пиков для каждой группы абонентов).

Учитывая количество вариаций распределения ресурсов, предварительный расчёт табличных параметров для всех сценариев нецелесообразен ввиду значительной вычислительной сложности. Однако, большинство сценариев

коррелируют с точки зрения параметров и могут быть аппроксимированы полиномами низкого порядка [17].

5.1 Предсказание гиперпараметров

Рассмотрим предсказание гиперпараметров (порогов отбора пиков) τ с помощью моделей регрессии $f(N_{RB}, ANL)$ из малопараметрического семейства. Данная задача является классической задачей аппроксимации функции. В данной постановке модель использует информацию о параметрах абонентов в каждой группе для вычисления (аппроксимации) порогов отбора пиков.

5.2 Методы обучения

В данной статье рассмотрено несколько моделей линейной аппроксимации, таких как обычная линейная регрессия (Ordinary Least squares, OLS) [18], RANSAC (RANdom SAMple Consensus, RANSAC) [19] и Theil-Sen [20], а также нелинейная модель многослойного перцептрона (MultiLayer Perceptron, MLP) [21].

1) OLS позволяет аппроксимировать линейную модель вектором коэффициентов, минимизируя суммы квадратов разности между наблюдаемыми и желаемыми величинами.

2) RANSAC оценивает модель по случайным подмножествам наблюдений и выбирает гипотезу, включающую максимум согласованных с моделью наблюдений. Это стохастический алгоритм, поэтому вероятность успешного восстановления модели зависит от числа итераций и доли согласованных с моделью наблюдений в тренировочном наборе данных.

3) Theil-Sen позволяет аппроксимировать линейную модель, используя медианное обобщение по нескольким измерениям. Метод устойчив к многомерным выбросам, однако, его надежность понижается с ростом размерности данных.

4) MLP предсказывает функцию нелинейно с помощью нейросети, обученной на наборе данных. Архитектура нейронной сети полносвязная с одним скрытым слоем. Входной слой имеет 6 нейронов, скрытый слой — 8 нейронов, а выходной слой — один нейрон. Каждый нейрон включает смещение и использует линейный выпрямитель в качестве функции активации (Rectified Linear Unit, ReLU). Нейроны в скрытом слое модели преобразуют значения из предыдущего слоя с помощью взвешенной суммы, за которой следует нелинейная функция активации.

6 Вычислительная сложность

Опишем сложность каждого шага алгоритма, за исключением поиска методом полного перебора, поскольку он не предполагает работу в режиме реального времени.

Метод выборочного резервирования тонов. Сложность определяется умножением матриц в (3) и (4), где S — матрица Фурье, сложность вычисления которой $O(N_{FFT} \log(N_{FFT}))$, что сопоставимо с типичной сложностью БПФ передатчика, преобразующего сигнал из частотной во временную область.

Алгоритм кластеризации. Вычислительная сложность зависит от количества активных абонентов N_{UE} и числа разбиений N_G . Число разбиений упорядоченного набора из N_{UE} элементов на фиксированное число N_G подмножеств равно $C_{N_{UE}-1}^{N_G-1} = \frac{(N_{UE}-1)!}{(N_G-1)!(N_{UE}-N_G)!}$. Поскольку вычисление $F(G)$ с

использованием уравнения (9) требует N_G умножений (операция вычисления квадратного корня выполняется с использованием таблицы поиска), следовательно, сложность алгоритма кластеризации равна $O\left(\frac{N_G(N_{UE}-1)!}{(N_G-1)!(N_{UE}-N_G)!}\right)$.

Например, в случае $N_G = 3$, $N_{UE} = 10$, кластеризация требует всего 108 умножителей, что, очевидно, намного меньше, чем у метода STR.

Обучение модели и прогнозирование значений. Обучение выполняется на известных данных в офлайн режиме, без влияния на онлайн-трафик. Далее, в режиме онлайн каждая модель использует набор N_{param} обученных параметров для прогнозирования порогового значения. Применение каждого параметра требует одного аппаратного умножителя, поэтому сложность составляет $O(N_{param})$. MLP требует наибольшего количества параметров среди других моделей. Однако, его сложность также не превосходит STR.

7 Результаты моделирования

В симуляциях были применены следующие параметры: количество абонентов $N_{UE} = 3$, количество групп $N_G = 2$, размер БПФ $N_{FFT} = 512$ количество используемых поднесущих $N_{SC} = 240$ ($N_{RB} = 20$), используемые модуляции: QPSK, QAM16, QAM64, QAM256, QAM1024. Максимальный динамический диапазон спектральной плотности мощности абонентов $P_{ratio} = 20$ дБ.

Корреляция прогнозируемых и оптимальных порогов представлена на рисунке 5, из которого следует, что предсказанные пороги коррелируют с оптимальными. Стоит отметить, что не наблюдается сильной корреляции между точностью предсказания порога в пространстве метрики порога и эффективностью снижения пик-фактора.

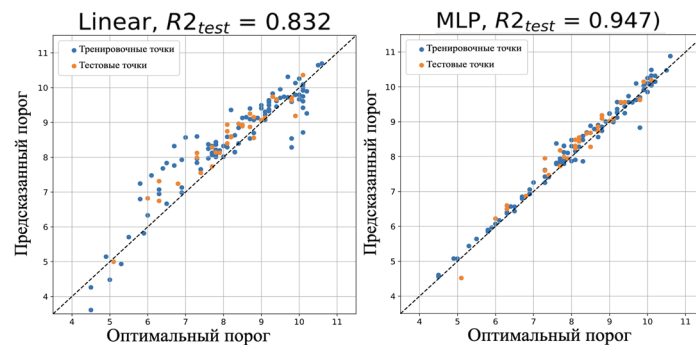


Рис. 5. Корреляция предсказанных и табличных порогов: линейная регрессия (слева), многослойный перцептрон (справа)

Для каждого случайно сгенерированного сценария распределения ресурсов было сгенерировано фиксированное количество псевдослучайных OFDM-символов. Количество сценариев в наборе данных составляет 128. Сценарии были разделены на обучающий и тестовый наборы в соотношении 3:1.

Для поиска оптимальных значений порога в алгоритме STR, они были дискретизированы на сетке из 81 равномерно распределенных точек. Поиск происходил методом полного перебора. Качество работы алгоритма на табличных и предсказанных порогах рассмотрено на конфигурациях сценариев, представленных в таблице 2.

Таблица 2

Сценарии распределения ресурсов между абонентами

Распределение ресурсов	Сценарий 1	Сценарий 2
Относительная мощность излучения, дБ	[7,0; 17,8; 15,4]	[16,5; 17,0; 7,0]
Тип модуляции	['QPSK', 'QPSK', 'QAM1024']	['QAM256', 'QPSK', 'QAM16']
Число RB	[9, 8, 3]	[4, 12, 4]
Найденное разбиение на 2 группы	[[0, 1], [2]]	[[2], [0, 1]]

Обученные значения включают коэффициенты масштабирования μ_k, σ_k и коэффициенты модели аппроксимации \mathbf{C} (вектор признаков) для каждой из моделей, где k — порядковый номер признака.

Процесс предсказания оптимального порога включает следующие шаги:

- 1) Создание общего вектора признаков $\mathbf{F} = [N_{RB}, ANL] = [f_1, \dots, f_k]$, f_k — элементы вектора \mathbf{F} ;
- 2) Нормализацию каждого признака с использованием стандартной процедуры масштабирования: $f_k^* = \frac{f_k - \mu_k}{\sigma_k}$;
- 3) Умножение нормализованного вектора признаков \mathbf{F} на вектор коэффициентов $\mathbf{C} = [c_1, \dots, c_k]$, c_k — элементы вектора \mathbf{C} . Затем, сложение элементов полученного вектора с последующим смещением B :

$$\tau_{pred} = \sum_k f_k c_k + B. \quad (12)$$

Дополнительные интегральные функции распределения для сценариев 1 и 2 представлены на рисунках 6 и 7 соответственно.

В сценарии 1 исходный пик-фактор равен 11,7 дБ. Алгоритм клиппирования и фильтрации позволяет достичь результата 10,5 дБ, в то время как после применения предложенного алгоритма пик-фактор уменьшается до диапазона 6,75-7,25 дБ, в зависимости от типа модели регрессии. Минимальное значение, найденное полным перебором, равно 6,6 дБ.

В сценарии 2 исходный пик-фактор также равен 11,7 дБ. Алгоритм клиппирования и фильтрации позволяет достичь результата 11,0 дБ, в то время как после применения предложенного алгоритма пик-фактор уменьшается до диапазона 7,5-7,75 дБ, в зависимости от типа модели регрессии. Минимальное значение, найденное полным перебором, равно 7,5 дБ.

Из результатов следует, что предложенный алгоритм позволяет достичь большего подавления пиков по сравнению с алгоритмом клиппирования и фильтрации.

Высокое качество достигается благодаря эффективной стратегии кластеризации абонентов. Более того, предложенный метод требует гораздо меньшего объема памяти и времени обучения. Важно отметить, что высокий порядок модуляции, при равной спектральной плотности мощности абонентов снижает допустимый уровень сигнала подавления пиков.

В рассмотренных экспериментах все методы оценки порога демонстрируют преимущество над клиппированием и фильтрацией. Несмотря на то, что MLP имеет множество параметров, он не превосходит другие алгоритмы.




Рис. 6. Дополнительная интегральная функция распределения для сценария 1




Рис. 7. Дополнительная интегральная функция распределения для сценария 2

Качественные результаты предсказания в виде срезов многомерной функции аппроксимации представлены на рисунке 8.




Рис. 8. Срез параметрического пространства для 3 различных распределений частотных ресурсов между абонентами

Данная конфигурация включает три абонента с модуляцией QAM256, распределенных в две группы. Каждый срез соответствует определенному распределению ресурсных блоков между абонентами. Наилучшие пороговые значения, достигаемые методом полного перебора, образуют плоскость в пространстве ANL_1 (группа 1), ANL_2 (группа 2) и порога.

Заключение

Согласно результатам моделирования, предложенный подход кластеризации абонентов позволяет эффективно использовать алгоритм выборочного резервирования тонов в OFDM-системах при неравномерном распределении ресурсов абонентов.

Пороги отбора пиков для метода выборочного резервирования тонов, найденные методом полного перебора, были успешно заменены многомерными линейными моделями (OLS, RANSAC, Theil-Sen) и нелинейной моделью (MLP) аппроксимации. Полученные приближения позволяют вычислять порог отбора пиков, избегая полного перебора, что открывает возможность использовать алгоритм в реальном времени.

Предсказание порогов отбора пиков при помощи линейной регрессии превзошло альтернативные модели по качеству компенсации пик-фактора.

Литература

1. *Chen W., Lin X., Lee J.* и др. 5G-Advanced Toward 6G: Past, Present, and Future // IEEE Journal on Selected Areas in Communications. 2023. Т. 41, № 6. С. 1592-1619.
2. *Zhao Y., Liu K., Liu Y.* An Efficient Linear Companding Approach for PAPR Reduction in Multi-User MIMO-OFDM Systems // 2023 IEEE 11th International Conference on Information, Communication and Networks (ICICN). 2023. С. 235-240.
3. *Abdulhussein A. A., Abdullah H. N.* Comparative Study of Peak to Average Power Ratio in OFDM and FBMC Systems // 2021 7th International Conference on Space Science and Communication (IconSpace). 2021. С. 140-145.
4. *Ohta M., Hayakawa T.* Deep Learning-Based PAPR Suppression of OFDM Signals with Clipping Constraint // 2024 International Technical Conference on Circuits/Systems, Computers, and Communications (ITC-CSCC). 2024. С. 1-4.
5. *Muneer S., Sjöland H., Edfors O., Liu L.* Low Complexity Clipping Distortion Compensation for PAPR Reduction in Massive MIMO-OFDM for Frequency Selective Channels // IEEE Transactions on Green Communications and Networking. 2025. С. 1-1.
6. *Liu X., Zhang X., Zhang L.* и др. PAPR Reduction Using Iterative Clipping/Filtering and ADMM Approaches for OFDM-Based Mixed-Numerology Systems // IEEE Transactions on Wireless Communications. 2020. Т. 19, № 4. С. 2586-2600.
7. *Guo F., He J., Zhou Y., Ge J.* An Improved Combination Algorithm for Tone Reservation and Active Constellation Extension Based on Least Squares Approximation // 2024 IEEE 24th International Conference on Communication Technology (ICCT). 2024. С. 1131-1135.
8. *Чан Ван Нгуа, Хоанг Ван Туан, Дворкович А.В.* Способ обработки шума клиппирования для снижения пик-фактора OFDM сигналов и устройство для его реализации // Патент РФ на изобретение № 2835883. Приоритет 13.06.2024. Дата гос. регистрации 5.03.2025.
9. *Liu Y., Cheng F., Yi J., Rao Y., Wan X.* PAPR and Sidelobe Reduction Using Tone Reservation in OFDM RadCom Systems // IEEE Sensors Journal. 2024. Т. 24, № 16. С. 26645-26658.
10. *Ivanov A., Lakontsev D.* Selective Tone Reservation for PAPR Reduction in Wireless Communication Systems // 2017 IEEE International Workshop on Signal Processing Systems (SiPS). 2017. С. 1-6.
11. *Mahakornpetch T., Sasithong P., Siddiqi M. Z., Pluempittiwiriyawej C.* PAPR Reduction in OFDM Signal Using Machine Learning Base Tone Reservation // 2023 25th International Multitopic Conference (INMIC). 2023. С. 1-4.
12. *Rexhepi G., Ranasinghe K. R. R., De Abreu G. T. F.* и др. Tone Reservation-Based PAPR Reduction Using Manifold Optimization for OFDM-ISAC Systems // 2025 IEEE Wireless Communications and Networking Conference (WCNC). 2025. С. 1-6.
13. *Ivanov A., Volokhatyi A., Lakontsev D., Yarotsky D.* Unused Beam Reservation for PAPR Reduction in Massive MIMO System // 2018 IEEE 87th Vehicular Technology Conference (VTC Spring). 2018. С. 1-5.
14. *De C. da Silva B. S., Souza P. H. C. de, Mendes L. L.* PAPR Reduction Technique for Mobile Communication Systems Using Neural Networks // IEEE Latin America Transactions. 2025. Т. 23, № 7. С. 556-564.
15. *Cheng X., Chen D., Li S., He S., Kong D.* A Novel PAPR Reduction Scheme Based on Deep Autoencoder Network for FBMC Systems // IEEE Access. 2025. Т. 13. С. 68948-68958.
16. *Zhang Q., Han R., Jiang C.* и др. End-to-End Joint Optimization for PAPR Reduction and Digital Predistortion Based on Neural Network // IEEE Microwave and Wireless Technology Letters. 2025. Т. 35, № 5. С. 509-512.
17. *Kalinov A., Bychkov R., Ivanov A., Osinsky A., Yarotsky D.* Machine Learning-Assisted PAPR Reduction in Massive MIMO // IEEE Wireless Communications Letters. 2021. Т. 10, № 3. С. 537-541.
18. *Xiao Z., Sun J., Zhang Z., Liu Y.* Nonparametric Regression for MU-MIMO Channel Prediction: From KNN to Local Linear Regression // IEEE Transactions on Wireless Communications. 2024. Т. 23, № 4. С. 2784-2795.
19. *Djurović I., Wojciechowski A.* Estimating Parameters of Signals with Hybrid Sinusoidal and Polynomial Modulation Using RANSAC-Based Approach // IEEE Transactions on Aerospace and Electronic Systems. 2025. Т. 61, № 2. С. 5377-5387.
20. *Fernandes R. A., Leblanc S. G.* Parametric (modified least squares) and non-parametric (Theil-Sen) linear regressions for predicting biophysical parameters in the presence of measurement errors // Remote Sensing of Environment. 2005. Т. 95. С. 303-316.
21. *Jiang F., Huang Z., Huang L., Yan H.* Multilayer Perceptron (MLP)-based Path Loss Prediction Modeling for LoRa Signals // 2024 4th International Conference on Artificial Intelligence, Robotics, and Communication (ICAIRC). 2024. С. 139-143

PAPR REDUCTION IN MULTI-USER FDD-OFDM SYSTEMS UNDER NON-UNIFORM RESOURCE ALLOCATION

Stanislav A. Krikunov, Skolkovo Institute of Science and Technology, Moscow, Russia, stanislav.krikunov@skoltech.ru

Andrey A. Ivanov, Skolkovo Institute of Science and Technology, Moscow, Russia, an.ivanov@skoltech.ru

Abstract

This article presents a machine-learning (ML) assisted method for peak-to-average power ratio (PAPR) reduction in the downlink of communication systems under non-uniform resource allocation among users. In a multiuser regime, the admissible error vector magnitude (EVM) varies with the allocated user resources such as bandwidth, modulation order, and transmit power. This complicates PAPR reduction by conventional techniques such as clipping and filtering, since the required number of iterations and algorithm parameters depend on the current user configuration and resource allocation. An optimal peak-suppression signal can be generated exactly in accordance with the EVM constraints using selective tone reservation (STR) method. However, in practice, this requires hyperparameter tuning via exhaustive search, which is infeasible in real time. We propose a method that achieves quasi-optimal peak suppression without costly real-time hyperparameter search. The method combines combinatorial clustering of users by admissible EVM while accounting for allocated resources, and STR method, where the peak-selection threshold is predicted using low-parameter ML models. Training is performed offline on a set of random scenarios. Simulation results demonstrate near-optimal peak suppression: the gap between the achieved PAPR and the attainable bound is below 0.5 dB. A high correlation between the predicted thresholds and those obtained by exhaustive search, confirming the validity of the model. For practical implementation, linear regression and a limited number of groups are recommended. The proposed approach is applicable to 5G systems.

Keywords: PAPR, OFDM, Machine Learning, Clustering, Regression.

References

- [1] W. Chen et al., "5G-Advanced Toward 6G: Past, Present, and Future," *IEEE Journal on Selected Areas in Communications*, vol. 41, no. 6, pp. 1592-1619, Jun. 2023, doi: 10.1109/JSAC.2023.3274037.
- [2] Y. Zhao, K. Liu, and Y. Liu, "An Efficient Linear Companding Approach for PAPR Reduction in Multi-User MIMO-OFDM Systems," in *Proc. IEEE 11th Int. Conf. Information, Communication and Networks (ICICN)*, Xi'an, China, 2023, pp. 235-240, doi: 10.1109/ICICN59530.2023.10392894.
- [3] A. A. Abdullhusein and H. N. Abdullah, "Comparative Study of Peak to Average Power Ratio in OFDM and FBMC Systems," in *Proc. 7th Int. Conf. Space Science and Communication (IconSpace)*, Selangor, Malaysia, 2021, pp. 140-145, doi: 10.1109/IconSpace53224.2021.9768772.
- [4] M. Ohta and T. Hayakawa, "Deep Learning-Based PAPR Suppression of OFDM Signals with Clipping Constraint," in *Proc. Int. Tech. Conf. Circuits/Systems, Computers and Communications (ITC-CSCC)*, Okinawa, Japan, 2024, pp. 1-4, doi: 10.1109/ITC-CSCC62988.2024.10628189.
- [5] S. Muneer, H. Sjöland, O. Edfors, and L. Liu, "Low Complexity Clipping Distortion Compensation for PAPR Reduction in Massive MIMO-OFDM for Frequency Selective Channels," *IEEE Transactions on Green Communications and Networking*, early access, 2025, doi: 10.1109/TGCN.2025.3604969.
- [6] X. Liu et al., "PAPR Reduction Using Iterative Clipping/Filtering and ADMM Approaches for OFDM-Based Mixed-Numerology Systems," *IEEE Transactions on Wireless Communications*, vol. 19, no. 4, pp. 2586-2600, Apr. 2020, doi: 10.1109/TWVC.2020.2966600.
- [7] F. Guo, J. He, Y. Zhou, and J. Ge, "An Improved Combination Algorithm for Tone Reservation and Active Constellation Extension Based on Least Squares Approximation," in *Proc. IEEE 24th Int. Conf. Communication Technology (ICCT)*, Chengdu, China, 2024, pp. 1131-1135, doi: 10.1109/ICCT62411.2024.10946441.
- [8] Chan Van Ngia, Khoang Van Tuan, and A. V. Dvorkovich, "Method of processing clipping noise to reduce peak factor OFDM signals and device for its implementation," RU Patent 2835883 C1, Mar. 5, 2025 (priority: Jun. 13, 2024).
- [9] Y. Liu, F. Cheng, J. Yi, Y. Rao, and X. Wan, "PAPR and Sidelobe Reduction Using Tone Reservation in OFDM RadCom Systems," *IEEE Sensors Journal*, vol. 24, no. 16, pp. 26645-26658, Aug. 15, 2024, doi: 10.1109/JSEN.2024.3418821.
- [10] A. Ivanov and D. Lakontsev, "Selective Tone Reservation for PAPR Reduction in Wireless Communication Systems," in *Proc. IEEE Int. Workshop on Signal Processing Systems (SiPS)*, Lorient, France, 2017, pp. 1-6, doi: 10.1109/SiPS.2017.8110018.
- [11] T. Mahakornpetch, P. Sasithong, M. Z. Siddiqi, and C. Pluempittiwiriyawej, "PAPR Reduction in OFDM Signal Using Machine Learning Based Tone Reservation," in *Proc. 25th Int. Multitopic Conf. (INMIC)*, Lahore, Pakistan, 2023, pp. 1-4, doi: 10.1109/INMIC60434.2023.10465808.
- [12] G. Rexhepi, K. R. R. Ranasinghe, G. T. F. De Abreu, and D. G. G., "Tone Reservation-Based PAPR Reduction Using Manifold Optimization for OFDM-ISAC Systems," in *Proc. IEEE Wireless Communications and Networking Conf. (WCNC)*, Milan, Italy, 2025, pp. 1-6, doi: 10.1109/WCNC61545.2025.10978830.
- [13] A. Ivanov, A. Volokhatyi, D. Lakontsev, and D. Yarotsky, "Unused Beam Reservation for PAPR Reduction in Massive MIMO System," in *Proc. IEEE 87th Vehicular Technology Conf. (VTC Spring)*, Porto, Portugal, 2018, pp. 1-5, doi: 10.1109/VTCSpring.2018.8417537.
- [14] B. S. de C. da Silva, P. H. C. de Souza, and L. L. Mendes, "PAPR Reduction Technique for Mobile Communication Systems Using Neural Networks," *IEEE Latin America Transactions*, vol. 23, no. 7, pp. 556-564, Jul. 2025, doi: 10.1109/TLA.2025.11045671.
- [15] X. Cheng, D. Chen, S. Li, S. He, and D. Kong, "A Novel PAPR Reduction Scheme Based on Deep Autoencoder Network for FBMC Systems," *IEEE Access*, vol. 13, pp. 68948-68958, 2025, doi: 10.1109/ACCESS.2025.3562066.
- [16] Q. Zhang, R. Han, C. Jiang, J. Wang, H. Chang, and F. Liu, "End-to-End Joint Optimization for PAPR Reduction and Digital Predistortion Based on Neural Network," *IEEE Microwave and Wireless Components Letters*, vol. 35, no. 5, pp. 509-512, May 2025, doi: 10.1109/LMWT.2025.3546643.
- [17] A. Kalinov, R. Bychkov, A. Ivanov, A. Osinsky and D. Yarotsky, "Machine Learning-Assisted PAPR Reduction in Massive MIMO," in *IEEE Wireless Communications Letters*, vol. 10, no. 3, pp. 537-541, March 2021, doi: 10.1109/LWC.2020.3036909.
- [18] Z. Xiao, J. Sun, Z. Zhang, and Y. Liu, "Nonparametric Regression for MU-MIMO Channel Prediction: From KNN to Local Linear Regression," *IEEE Transactions on Wireless Communications*, vol. 23, no. 4, pp. 2784-2795, Apr. 2024, doi: 10.1109/TWVC.2023.3303024.
- [19] I. Djurović and A. Wojciechowski, "Estimating Parameters of Signals With Hybrid Sinusoidal and Polynomial Modulation Using RANSAC-Based Approach," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 61, no. 2, pp. 5377-5387, Apr. 2025, doi: 10.1109/TAES.2024.3466837.
- [20] R. A. Fernandes and S. G. Leblanc, "Parametric (modified least squares) and non-parametric (Theil-Sen) linear regressions for predicting biophysical parameters in the presence of measurement errors," *Remote Sensing of Environment*, vol. 95, pp. 303-316, 2005, DOI:10.1016/J.RSE.2005.01.005.
- [21] F. Jiang, Z. Huang, L. Huang, and H. Yan, "Multilayer Perceptron (MLP)-Based Path Loss Prediction Modeling for LoRa Signals," in *Proc. 4th Int. Conf. Artificial Intelligence, Robotics, and Communication (ICAIRC)*, Xiamen, China, 2024, pp. 139-143, doi: 10.1109/ICAIRC64177.2024.10900202.

Information about authors:

Stanislav A. Krikunov, graduate student, Skolkovo Institute and Technologies, Moscow, Russia. ORCID: 0009-0001-9775-3564

Andrey A. Ivanov, Ph.D., Professor, Skolkovo Institute and Technologies, Moscow, Russia. ORCID: 0009-0001-9775-3564