

УДК 621.376

<https://doi.org/10.31854/2307-1303-2025-13-4-54-70>

EDN: NASEQO

Моделирование методов машинного обучения для улучшения качества связи в коротковолновом канале радиосвязи

Исаков М. В., Симонина О. А. ✉

Санкт-Петербургский государственный университет телекоммуникаций им. проф. М. А. Бонч-Бруевича, Санкт-Петербург, 193232, Российская Федерация

Актуальность. В настоящее время коротковолновый диапазон по-прежнему сохраняет свою значимость как экономически эффективное решение для дальней связи. При этом существует ряд проблем в области методов повышения эффективности коротковолновых каналов в условиях сложной ионосферной обстановки. Применение технологий машинного обучения открывает новые возможности для улучшения качества связи. **Цель исследования** – повышение качества связи в коротковолновом канале связи посредством применения методов машинного обучения для демодуляции сигналов с использованием технологий OFDM. **Методы исследования:** моделирование LSTM-сетей для прогнозирования ионосферных параметров, применение сверточных сетей (CNN) и многослойных перцептронов (MLP) для демодуляции сигналов. **Научная новизна** состоит в комплексном подходе к улучшению качества связи в коротковолновом канале связи, объединяющем прогнозирование ионосферных параметров с методами машинного обучения для демодуляции сигналов. **Результаты исследования.** Применение CNN-демодуляторов обеспечивает наилучшее качество приема сигналов при низких значениях отношения сигнал / шум, демонстрируя выигрыш до 2,5 дБ по сравнению с классическим корреляционным методом. LSTM-сети показали высокую эффективность в прогнозировании максимально применимых частот и других ионосферных параметров. **Практическая значимость:** разработаны методы повышения качества связи в коротковолновом диапазоне, которые могут быть использованы для создания адаптивных систем радиосвязи с автоматическим выбором рабочих частот и параметров модуляции.

Ключевые слова: коротковолновая связь, OFDM, машинное обучение, LSTM-сети, CNN, MLP, демодуляция, прогнозирование ионосферы, качество связи

Введение

В условиях современного развития технологий радиосвязи и телекоммуникаций коротковолновый (КВ) диапазон сохраняет свою актуальность как экономически эффективное решение для дальней связи без использования ретрансляторов [1]. При этом для повышения качества связи все более перспективным направлением развития современных телекоммуникационных систем становится

Библиографическая ссылка на статью:

Исаков М. В., Симонина О. А. Моделирование методов машинного обучения для улучшения качества связи в коротковолновом канале радиосвязи // Информационные технологии и телекоммуникации. 2025. Т. 13. № 4. С. 54–70. DOI: 10.31854/2307-1303-2025-13-4-54-70. EDN: NASEQO

Reference for citation:

Isakov M., Simonina O. Simulation of Machine Learning Methods to Improve Communication Quality in a Short-Wave Radio Channel // Telecom IT. 2025. Vol. 13. Iss. 4. PP. 54–70. (in Russian) DOI: 10.31854/2307-1303-2025-13-4-54-70. EDN: NASEQO

использование различных методов искусственного интеллекта (ИИ), хорошо зарекомендовавших себя для прогнозирования условий в радиоканале, обработки радиосигналов, а также настройки параметров приема и передачи. Применение данных методов позволяет изменять и адаптировать параметры радиосигнала под изменяющиеся условия ионосферы, чтобы снизить негативное воздействие помех и ионосферных возмущений, добиться наилучшего качества связи [2, 3].

В настоящее время для КВ-связи используются группы методов, позволяющие существенно улучшить качество. Например, технология ортогонального мультиплексирования с частотным разделением канала (OFDM, *аббр. от англ. Orthogonal Frequency-Division Multiplexing*), позволяющая повысить устойчивость к многолучевому распространению, в КВ-связи используется совместно с адаптивными, сигнально-кодowymi и пространственными методами [4, 5]. Также в настоящее время различные методы ИИ применяются для повышения эффективности, надежности и адаптивности систем связи. В КВ-связи это группы задач, связанных с высокой изменчивостью ионосферных условий и необходимостью быстрой адаптации к помехам. Например, в некоторых работах [6–8] предлагается использовать методы ИИ для выбора оптимальных частот КВ-связи. В работе [9] предлагается использовать нейронные сети для подавления помех, в том числе в КВ-каналах. Для решения проблемы радиолокационных помех успешно используют детектор на основе глубокой нейронной сети (DNN, *аббр. от англ. Deep Neural Network*) [10].

Использование машинного обучения

Использование машинного обучения позволяет системе адаптироваться к сложным и изменчивым условиям ионосферного распространения радиоволн, сохранять устойчивость к нестационарности радиоканала. Рассмотрим возможность создания системы прогнозирования ионосферных параметров с использованием нейронных LSTM-сетей (*аббр. от англ. Long Short-Term Memory – долговременная краткосрочная память*).

Сеть LSTM – это особый тип рекуррентной нейронной сети (RNN, *аббр. от англ. Recurrent Neural Network*), который способен обучаться долговременным зависимостям. Также совместно с использованием LSTM-сетей можно применять методы машинного обучения с учителем (Supervised Learning). Преимуществом использования LSTM-сетей для ионосферного прогнозирования является возможность учета временной корреляции шумов, поиск краткосрочных и долгосрочных зависимостей. Данный тип сети учитывает краткосрочные флуктуации (шум, быстрые возмущения и помехи), среднесрочные циклы (суточные изменения) и долгосрочные закономерности при наличии достаточных данных. Отметим, что данные сети учитывают нелинейности усилителей, квантования [11], а также способны к эффективному разделению сигнала и помех по мере обучения [12].

Особенностью LSTM-сетей является наличие различных элементов управления [13]. Элементы управления забыванием решают, какую информацию отбросить из предыдущего состояния, сопоставляя его с текущим вводом

со значением от 0 до 1. Значение 1 означает сохранение информации, значение 0 – отбрасывание. Элементы ввода решают, какие фрагменты новой информации сохранить в текущем состоянии ячейки и применять для оценки. Элементы управления выводом указывают, какие фрагменты информации в текущем состоянии ячейки выводить, присваивая информации значение от 0 до 1 с учетом предыдущего и текущего состояний.

Таким образом, полнофункциональная система прогнозирования ионосферных параметров с использованием LSTM-сетей может быть использована для многозадачного прогнозирования ключевых параметров ионосферной радиосвязи, таких как максимально применимая частота (MUF, аббр. от англ. Maximum Usable Frequency), отношения сигнал / шум (SNR, аббр. от англ. Signal-to-Noise Ratio) и глубина замираний [14–16].

Моделирование КВ-канала связи

Значения MUF зависят от солнечной активности, сезона и времени суток, а также от состояния ионосферных слоев в данный момент¹. На рисунке 1 приведен график зависимости MUF от времени суток, построенный на основе сгенерированных данных согласно Рекомендации МСЭ-R P.1239-1.

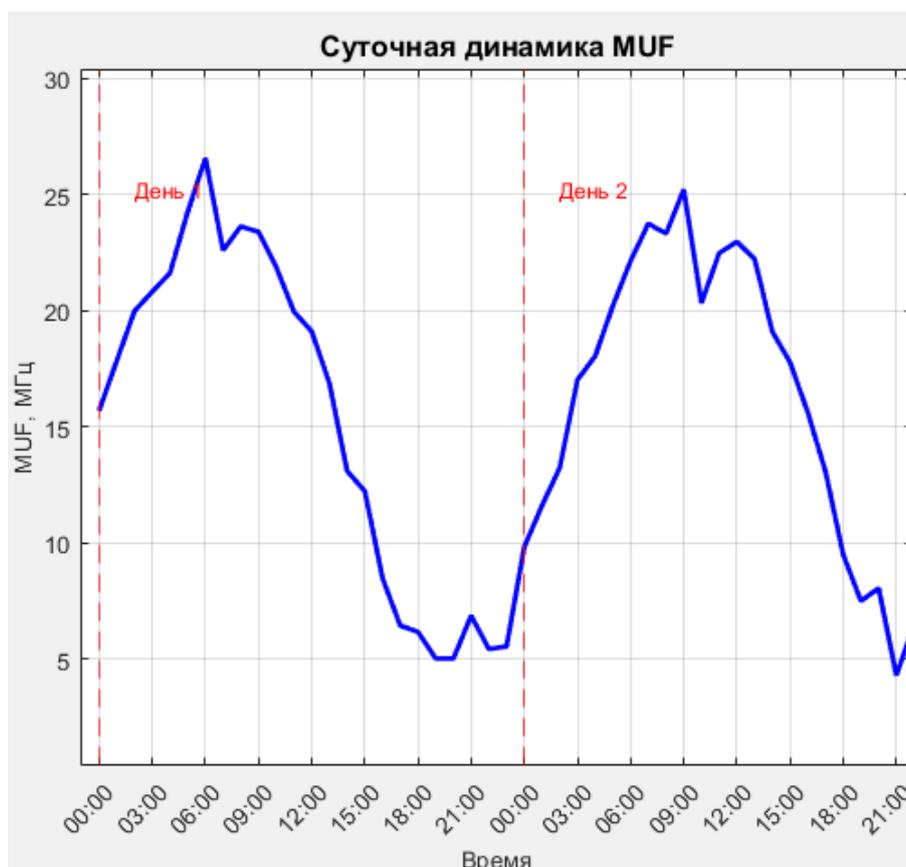


Рис. 1. Суточная динамика MUF

¹ Рекомендация МСЭ-R P.1239 1. Эталонные характеристики ионосферы, разработанные МСЭ R. URL: https://www.itu.int/dms_pubrec/itu-r/rec/p/R-REC-P.1239-1-200702-S!!PDF-R.pdf (дата обращения 11.12.2025).

В процессе моделирования условий КВ-канала передачи радиосигнала были получены графики функции потерь (Loss) и корня из среднеквадратичной ошибки (RMSE, *аббр. от англ. Root Mean Squared Error*). Выбор данных показателей обусловлен тем, что их графики дают представление о динамике адаптации модели к изменяющимся условиям распространения радиоволн.

Loss – основная целевая функция, которую нейронная сеть пытается минимизировать в процессе обучения. Она позволяет учитывать специфику искажений в КВ-канале (замирания, межсимвольная интерференция и т. д.). Это количественная мера, показывающая, насколько отличаются прогнозы модели по сравнению с целевыми (фактическими) значениями. Минимизация этой функции соответствует максимизации правдоподобия оценки параметров сигнала.

Обычно для регрессии используется среднеквадратическая ошибка (MSE). В начале моделирования высокие значения ошибок обусловлены тем, что система делает случайные прогнозы, но по мере обучения неверные прогнозы отбрасываются, а верные учитываются в дальнейших итерациях. Таким образом, наблюдается постепенное уменьшение количества ошибок моделирования. Для улучшения обучаемости данной модели можно увеличить количество LSTM-слоев и итераций. Стоит отметить, что в какой-то момент модель достигает своего предела обучаемости и дальнейшее увеличение итераций не будет способствовать уменьшению ошибок.

Выбранный целевой показатель RMSE является более интерпретируемой метрикой, чем MSE, поскольку имеет ту же размерность, что и исходные данные, поэтому позволяет сразу оценить среднюю ошибку прогноза. Также RMSE чувствителен к большим отклонениям и позволяет сравнивать результаты моделирования при разных конфигурациях канала. Он рассчитывается по формуле:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2},$$

где N – общее количество наблюдений; y_i и \hat{y}_i – фактическое и предсказанное значение для i -го наблюдения соответственно.

Таким образом, изменение этих показателей дает оценку точности предсказания параметров системы, стабильности при изменении условий, достигнутого качества связи на основе прогнозов, а также практической точности прогнозов в физических единицах. На рисунке 2 приведен пример графиков RMSE и Loss для прогнозирования суточного изменения MUF.

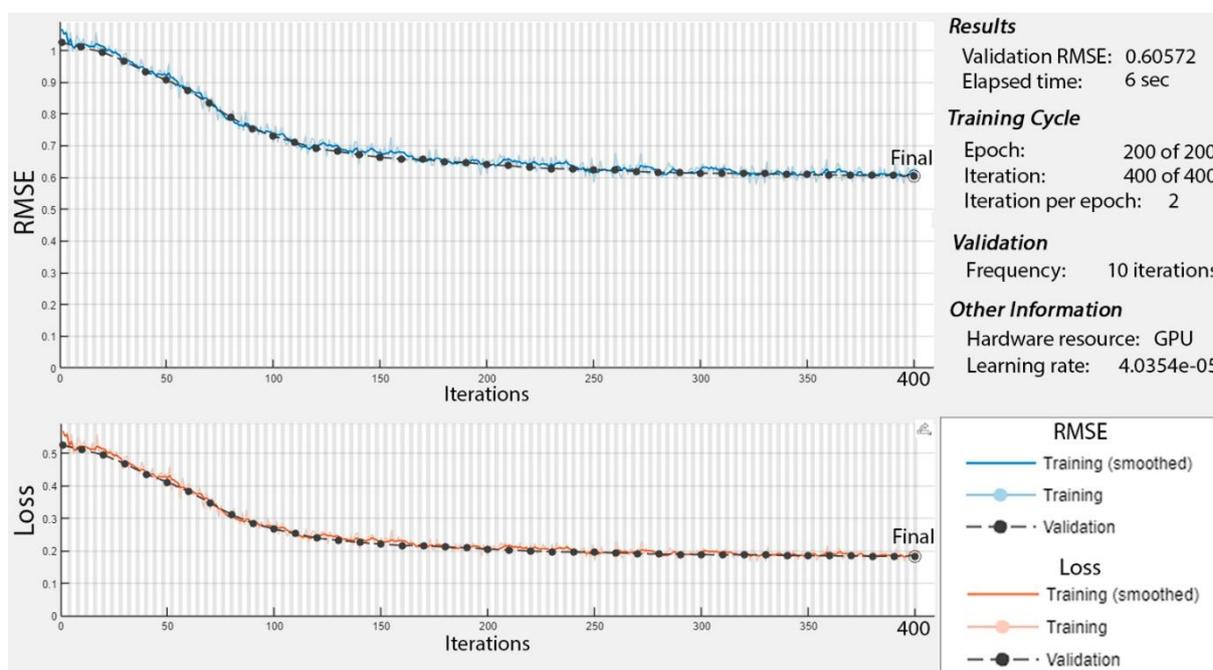


Рис. 2. Графики RMSE и Loss для MUF

Демодулятор на основе нейронных сетей

Традиционные методы демодуляции, такие как корреляционный детектор или стандартная QPSK-демодуляция (*аббр. от англ. Quadrature Phase Shift Keying* – квадратурная фазовая манипуляция), хорошо работают при чистом канале с аддитивным белым гауссовским шумом (AWGN, *аббр. от англ. Additive White Gaussian Noise*), однако в условиях импульсных помех, доплеровского сдвига и замираний сигнала эффективность классических алгоритмов снижается [17, 18]. При этом искусственные нейронные сети, в частности сверточные нейронные сети (CNN, *аббр. от англ. Convolution Neural Networks*), способны автоматически выделять устойчивые к шуму признаки в комплексном OFDM-сигнале и обеспечивать более надежную демодуляцию [19]. CNN в контексте обработки сигналов связи работают по принципу распознавания схожих паттернов в принимаемых сигналах. В отличие от классических алгоритмов, которые используют заранее заданные математические модели канала, CNN обучаются на данных и самостоятельно выявляют сложные нелинейные закономерности.

Структура CNN-демодулятора включает кодер и декодер. Первый кодирует входную последовательность символов и отображает признаки сигнала в пространство скрытого слоя, а второй декодирует их для получения результата демодуляции входной последовательности. К параметрам, которые оцениваются CNN при демодуляции радиосигнала, относится импульсная характеристика канала, замирания и задержки сигналов, наличие межсимвольной интерференции.

Стоит отметить, что данный тип демодуляторов оценивает величину доплеровского сдвига и наличие интерференции между поднесущими, а также производит оценку помех, которые исказили полученный радиосигнал, т. е. автоматически определяет тип помехи, мощность и время воздействия.

К преимуществам CNN относится извлечение признаков согласно иерархии слоев. Следовательно, первые слои обнаруживают простые признаки (резкие изменения амплитуды, фазовые скачки), средние слои комбинируют эти признаки, т. е. распознают многолучевые компоненты и доплеровские искажения, а глубокие слои выявляют сложные зависимости (корреляции между символами, структуру помех в радиосигнале). В процессе обработки радиосигнала и обучения применяются весовые категории и выявляются временные зависимости, которые впоследствии позволяют системе заранее предсказывать характеристики радиоканала (затухание сигнала, уровень помех, вероятность ошибки) и адаптироваться к условиям радиоканала [19].

В модели использована $1D / 2D$ CNN-структура. Входной слой принимает данные размером $[N_{sub} \cdot 1 \cdot 2]$, где N_{sub} – число поднесущих, а два канала соответствуют действительной и мнимой частям сигнала после преобразования Фурье (FFT, *аббр. от англ.* Fast Fourier Transform).

Сверточные слои выделяют пространственно-частотные особенности сигнала, для чего применяются фильтры, которые одновременно обрабатывают группы соседних поднесущих, улавливая локальные корреляции и паттерны в частотной области. Далее осуществляется нормализация активаций с последующим применением нелинейной функции преобразования, что способствует ускорению сходимости процесса обучения, снижению эффекта исчезающего градиента и повышению общей устойчивости архитектуры нейронной сети к вариациям входных данных. Полносвязный слой преобразуют извлеченные признаки в вероятности для четырех возможных QPSK-символов (00, 01, 10, 11). В процессе обучения CNN идентифицирует устойчивые к воздействию шума признаки и выявляет статистические закономерности в данных, что обеспечивает успешную демодуляцию сигналов даже при значительной степени их искажения. Таким образом, данная система обеспечивает нелинейность обработки, которая превосходит классические линейные методы [20].

Недостатком системы является необходимость наличия и изучения тренировочных данных, отражающих реальную динамику ионосферного радиоканала. Стоит отметить, что моделирование и обучение занимают больше времени, чем при использовании классических методов, но с увеличением количества тренировок значительно возрастает эффективность системы. Производительность зависит от архитектуры сети и объема обучающей выборки. CNN-демодулятор демонстрирует явное преимущество перед классическими методами в сложных условиях КВ-канала радиосвязи, таких как импульсный шум, доплеровский сдвиг и замирания [19, 21]. В реальном применении этот подход позволяет увеличить надежность передачи и снизить количество ошибок при OFDM-демодуляции QPSK-сигналов.

Так как КВ-сигналы, хотя и имеют временную структуру, не обладают явной пространственной организацией, критически важной для эффективности CNN, в качестве альтернативы рассмотрим MLP (*аббр. от англ.* Multi-Layer Perceptron – многослойный перцептрон) – тип искусственной нейронной сети с полностью связанными слоями. Этот вариант выбран из-за более простой ар-

хитектуры, меньшей потребности в обучающих данных и лучшей приспособленности к обработке векторных сигналов без явной пространственной структуры, особенно в условиях высокого уровня шума [22, 23]. В контексте демодуляции OFDM-сигналов MLP принимает на вход вектор, сформированный из реальной и мнимой частей FFT-выхода OFDM-блока. Достоинством MLP является возможность обработки сложных нелинейных эффектов, что позволяет компенсировать искажения из-за импульсного шума, доплеровского сдвига и замираний при условии обучения на подходящей выборке.

Структура MLP включает входной и выходной слои, а также несколько скрытых слоев [24]. MLP в отличие от CNN не использует локальные фильтры, а обрабатывает входной вектор целиком, что позволяет моделировать сложные нелинейные искажения КВ-канала. Однако MLP не учитывает локальные корреляции между поднесущими: в OFDM-системах соседние поднесущие часто испытывают схожие искажения, и CNN эффективно использует эту особенность за счет операций свертки, что позволяет им демонстрировать более высокую эффективность при работе со спектральными данными [25]. Кроме того, MLP характеризуется значительной чувствительностью к размеру входного вектора: при увеличении числа поднесущих количество настраиваемых параметров растет, что приводит к замедлению процесса обучения. Сравнение рассмотренных методов на основе CNN и MLP приведено в таблице 1.

Таблица 1. Сравнение методов машинного обучения CNN и MLP

| Метод | Преимущества | Недостатки |
|-------------------------------|--|---|
| Корреляционный (классический) | Простая реализация, низкая вычислительная сложность, хорошо работает при чистом канале с AWGN | Чувствителен к импульсному шуму, доплеровскому сдвигу и замираниям, график BER медленно убывает |
| MLP-демодулятор | Обрабатывает нелинейные искажения, выше скорость обучения | Не учитывает локальные зависимости, требует много данных, медленное обучение при большом числе поднесущих |
| CNN-демодулятор | Выделяет локальные особенности (связь соседних поднесущих), более устойчив к шуму и доплеровскому сдвигу, график BER убывает быстрее | Сложнее в реализации, требуется графический процессор для быстрой тренировки, больше вычислений |

Таким образом, классический корреляционный метод эффективно работает при чистом канале с AWGN, однако чувствителен к импульсным помехам и эффекту Доплера, что ограничивает его применимость в реальных КВ-каналах. MLP-демодулятор учитывает нелинейные искажения и частично компенсирует шумы и замирания, но не принимает во внимание локальные корреляции между соседними поднесущими, из-за чего в сложных каналах демонстрирует более низкую производительность по сравнению с CNN. CNN-демодулятор использует сверточные фильтры для выделения устойчивых при-

знаков в спектре OFDM-сигнала, что позволяет эффективно учитывать локальные зависимости между поднесущими, что делает сеть более устойчивой к шуму, импульсам и доплеровским сдвигам.

Моделирование демодулятора на основе нейронных сетей

Моделирование проводилось в среде MATLAB / Simulink на персональном компьютере, основные характеристики компонентов которого приведены в таблице 2.

Таблица 2. Параметры компонентов персонального компьютера

| Компонент | CPU Intel Core i5-13600K | GPU ASUS GeForce RTX 3060 | Оперативная память Adata XPG DDR5 |
|----------------------|--------------------------------|---------------------------|-----------------------------------|
| Архитектура / Модель | Raptor Lake (ядро GA106) | Ampere (ядро GA106) | Планки DDR5 (модуль DIMM) |
| Ядра / Поток | 14 ядер (6P + 8E) / 20 потоков | 3584 ядра CUDA | — |
| Тактовая частота | до 5,1 ГГц (P-cores, Turbo) | до 1,88 ГГц | 4800 МГц (эффективная, JEDEC) |
| Кэш / Память | 24 МБ L3 + 20 МБ L2 | 12 ГБ GDDR6 (192 бит) | Объем модуля: 2×16 ГБ |

В данном моделировании параметры OFDM-системы остаются постоянными, т. е. количество поднесущих, длина циклического префикса и тип модуляции не меняются при новых испытаниях. Количество OFDM-поднесущих при моделировании составляет 64, циклический префикс – 1/8. В каждой итерации обучения используется модуляция QPSK, полоса пропускания – 2,4 кГц. Для современных цифровых систем в КВ-канале с OFDM применяется Рекомендация МСЭ-R P.533-14², учитывающая распределение Релея – Райса для амплитудных замираний, модель Ваттерсона для многолучевости, а также различные значения доплеровских сдвигов.

В данном случае системой с целевыми параметрами BER и SNR является модель радиоканала, в которой отсутствуют факторы, негативно воздействующие на радиосигнал (замирания, импульсные помехи и доплеровские эффекты), а для построения моделей корреляционного метода, CNN и MLP применяются условия приближенные к реальным.

Основным параметром оценки качества сигнала является SNR, диапазон которого составляет от 0 до 20 дБ. Системы на основе MLP и CNN должны обучаться во всем диапазоне, чтобы моделирование могло отражать реальные условия КВ-каналов радиосвязи. Наличие шумов при передаче радиосигнала также

² Рекомендация МСЭ-R P.533 14. Метод прогнозирования рабочих характеристик ВЧ-линий связи. Серия Р. Распространение радиоволн. 2019. URL: https://www.itu.int/dms_pubrec/itu-r/rec/p/R-REC-P.533-14-201908-I!!PDF-R.pdf (дата обращения 11.12.2025).

необходимо для обучения данных систем. В процессе моделирования используются AWGN и импульсные помехи, вероятность, мощность и длительность которых варьируются в каждой итерации обучения. Доплеровский сдвиг составляет от 0,1 до 30 Гц. MUF также изменяется в процессе обучения, чтобы приблизить условия модели к реальным: ночью целесообразно использовать низкие частоты 3–10 МГц, а днем 15–30 МГц. При моделировании используется K -фактор Райса – параметр, который характеризует затухание сигнала в многолучевых каналах связи и определяет отношение мощности прямого пути распространения к мощности всех остальных путей. Значения K -фактора находятся в диапазоне от 0 до 10: если значение равно 0, то прямого луча нет и присутствуют сильные Релеевские замирания, при 10 прямой луч сильный, замирания минимальные.

Демонстрация эффективности систем на основе MLP и CNN требует проведения нескольких этапов моделирования, каждый из которых будет включать разное количество итераций обучения, для демонстрации повышения эффективности работы методов машинного обучения по мере увеличения количества итераций, в которых содержатся различные параметры КВ-канала. Эффективность и скорость обучения также зависят от наличия целевых показателей, которых должна достигнуть система с ИИ в процессе обучения и адаптации к условиям радиоканала.

На рисунке 3 приведены графики зависимости BER от SNR: для системы с целевыми параметрами, для корреляционного метода демодуляции, для демодуляторов MLP и CNN без обучения.

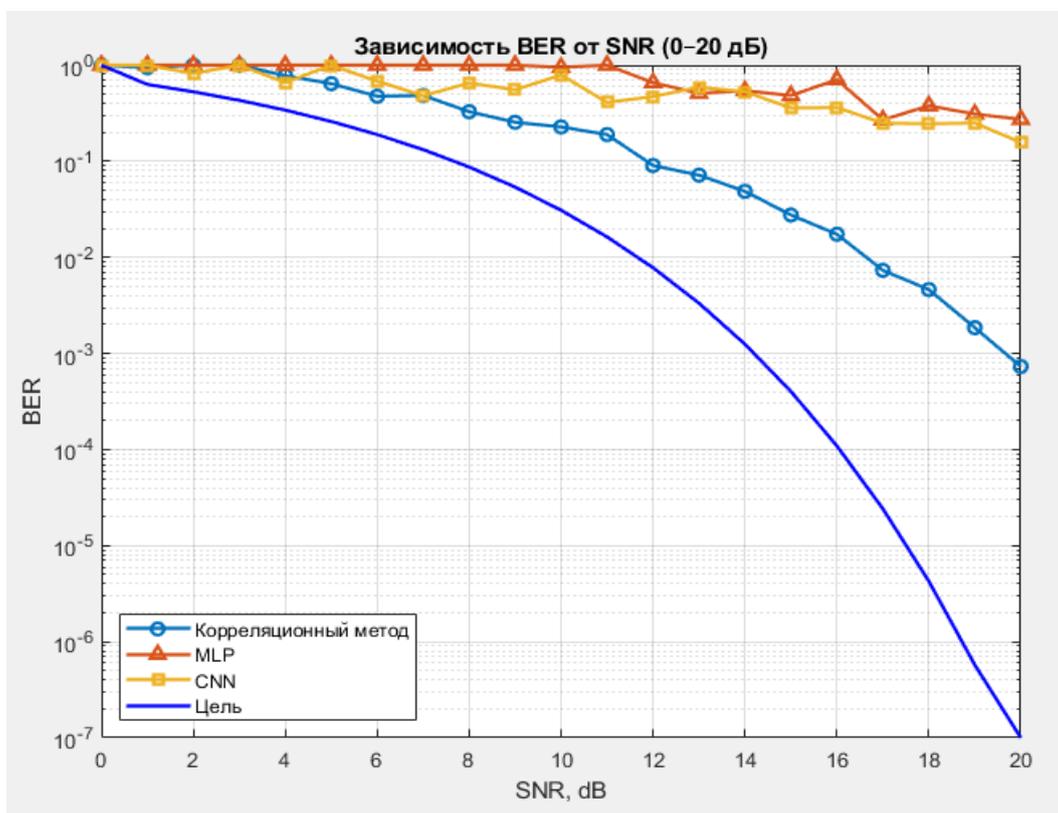


Рис. 3. График зависимости BER от SNR для классического корреляционного метода, MLP- и CNN-демодуляторов (без обучения)

Видно, что наиболее эффективным на данный момент является корреляционный метод демодуляции радиосигнала. Его эффективность достигается за счет сопоставления полученного сигнала с набором эталонных сигналов (шаблонов), соответствующих возможным передаваемым символам. Следовательно, классический корреляционный метод работает без обучения и является наиболее быстрым методом демодуляции. В моделях, которые используют методы машинного обучения, параметры демодуляции подбирались случайным образом и в большинстве случаев появлялись ошибки, так как системы еще не обучены и не могут корректно адаптировать параметры демодуляции, опираясь на предыдущие результаты.

Стоит отметить, что наличие «кривых» участков на графиках обусловлено воздействием импульсных помех и замираний, которые негативно влияют на качество приема и демодуляции радиосигналов.

На рисунке 4 представлен график зависимости BER от SNR для классического корреляционного метода, MLP- и CNN-демодуляторов при 600 итерациях обучения. Моделирование 600 итераций обучения было произведено за 8,1 с для MLP и 8,6 с для CNN. Наилучший результат показывает CNN-система, дающая выигрыш около 2,5 дБ относительно корреляционного метода и 1,3 дБ относительно решения на основе MLP при $BER = 10^{-3}$.

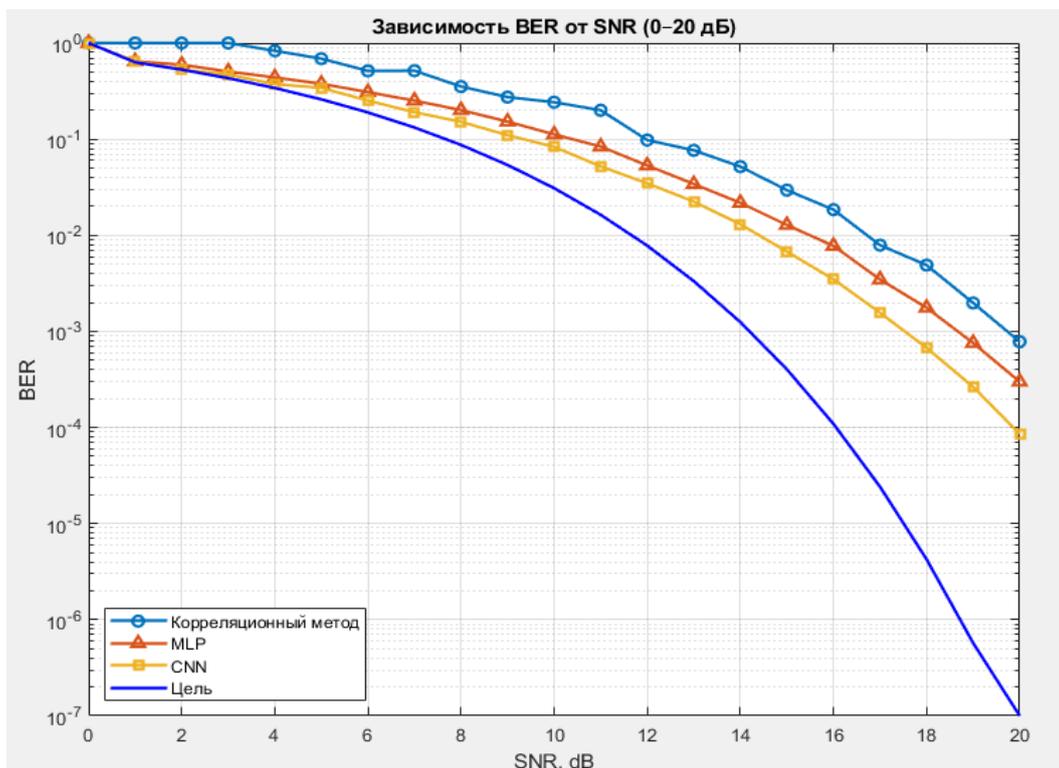


Рис. 4. График зависимости BER от SNR для классического корреляционного метода, MLP- и CNN-демодуляторов (600 итераций обучения)

На рисунке 5 представлен график, показывающий величину отклонения BER от целевых значений для каждого из методов демодуляции радиосигнала.

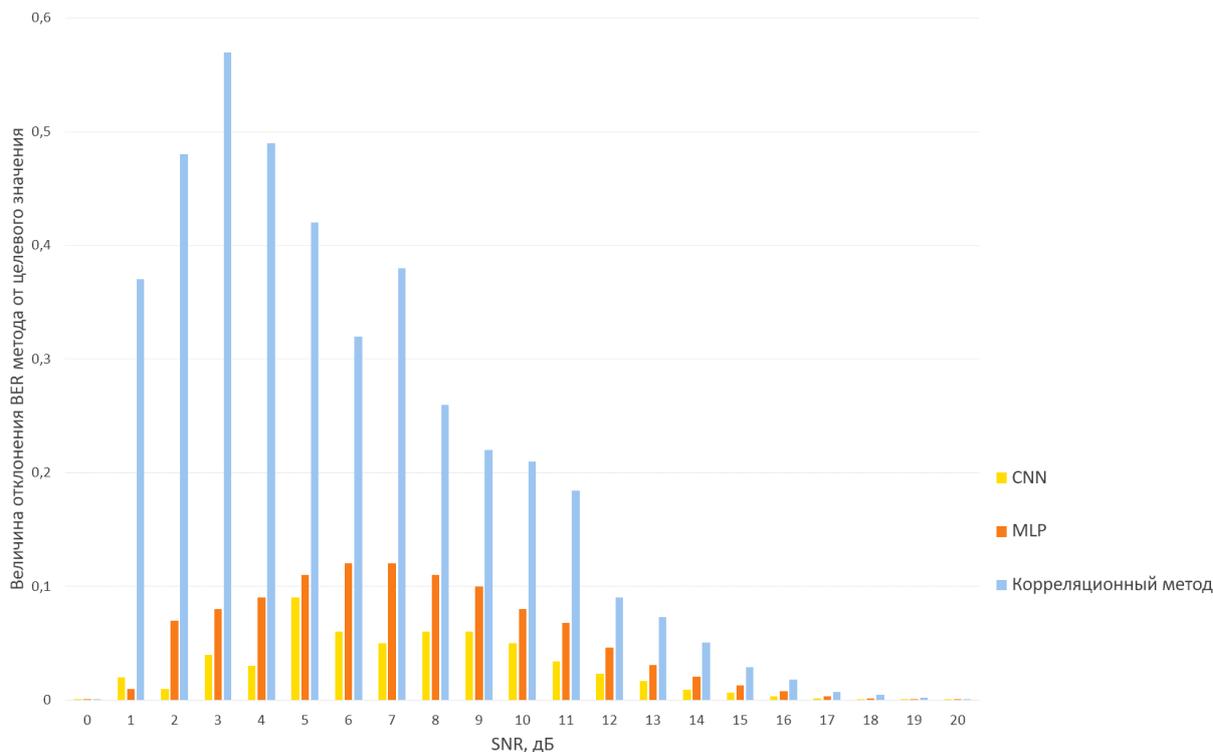


Рис. 5. График величины отклонения BER от целевого значения для различных методов демодуляции

Полученные значения позволяют сделать вывод, что методы машинного обучения являются более эффективными способами демодуляции радиосигнала, чем классический корреляционный метод, при этом наибольший прирост качества связи достигается при низких значениях SNR. Например, при $SNR = 7$ дБ методы на основе MLP и CNN относительно корреляционного метода показывают в 3,2 и 7,6 раза меньшую ошибку соответственно.

Заключение

Как показало моделирование, методы машинного обучения CNN и MLP позволяют поддерживать связь даже в условиях сильно возмущенной ионосферы, когда радиосигнал приходит с различными искажениями вследствие воздействия на него замираний, доплеровского эффекта, импульсных помех и шумов. Данное преимущество достигается за счет большого количества циклов обучения систем с ИИ, которые постепенно адаптируются к изменяющимся условиям ионосферы и позволяют выработать наиболее эффективные стратегии демодуляции радиосигнала для достижения наилучшего качества связи. При достаточном количестве итераций обучения CNN-демодулятор достигает наименьшего количества ошибок при демодуляции радиосигнала за счет выделения в спектре сигнала локальных особенностей среди соседних поднесущих и нелинейных искажений.

Таким образом, в процессе моделирования было установлено, что демодуляция на основе CNN является наиболее эффективным методом машинного обу-

чения и позволяет значительно снизить количество ошибок при приеме радиосигнала, особенно при низких значениях SNR. В условиях спокойной ионосферы, малых значений доплеровских сдвигов и отсутствии сильных импульсных помех корреляционный метод может стать предпочтительным способом демодуляции радиосигнала, так как не требует времени на обучение и является эффективным при высоких значениях SNR. В дальнейшем необходимо провести исследование по определению оптимального количества итераций обучения.

Литература

1. Ватрухин Е. М. Новые возможности применения коротковолновой радиосвязи при решении боевой авиацией задач воздушно-космической обороны // Вестник Концерна ВКО «Алмаз–Антей». 2017. № 2 (21). С. 16–20. EDN: YOBVLS
2. Чихачев А. В., Будко П. А., Шмидт А. А. Применение алгоритмов машинного обучения для решения задач прогнозирования технического состояния средств радиосвязи // Телекоммуникации и связь. 2024. № 3 (3). С. 33–40. DOI: 10.24682/3034-4050-2024-3-33-40. EDN: IDTCNI
3. Широков С. Ю. Исследование влияния искусственного интеллекта на оптимизацию процессов передачи данных // Вестник науки. 2024. Т. 4. № 12 (81). С. 1685–1689. EDN: AREGOJ
4. Егоров В. В., Мингалев А. Н., Щеглова Е. Ф. Многопараметрическая адаптация в коротковолновых системах передачи данных сигналами OFDM // Техника средств связи. 2021. № 3 (155). С. 18–28. EDN: LYRHQF
5. Землянов И. С. Модемы с ортогональными поднесущими мобильных систем коротковолновой связи с адаптацией к условиям распространения радиоволн. Дис. ... канд. техн. наук. Омск, 2016. 168 с. EDN: NQMQRТ
6. Конкин Н. А. Методика и алгоритм определения периодов оперативного прогнозирования динамики максимально применимых частот КВ-связи на основе алгоритма машинного обучения XGBoost // Вестник Поволжского государственного технологического университета. Серия: Радиотехнические и инфокоммуникационные системы. 2022. № 3 (55). С. 6–16. DOI: 10.25686/2306-2819.2022.3.6. EDN: ZPKQBM
7. Wang J., Shi Y., Yang C., Feng F. A Review and Prospects of Operational Frequency Selecting Techniques for HF Radio Communication // Advances in Space Research. 2022. Vol. 69. Iss. 8. PP. 2989–2999. DOI: 10.1016/j.asr.2022.01.026. EDN: GAQWAW
8. Liu X., Xu Yu., Cheng Yu., Li Ya., Zhao L., et al. A Heterogeneous Information Fusion Deep Reinforcement Learning for Intelligent Frequency Selection of HF Communication // China Communications. 2018. Vol. 15. Iss. 9. PP. 73–84. DOI: 10.1109/CC.2018.8456453
9. Oyedare T., Shah V. K., Jakubisin D. J., Reed J. H. Interference Suppression Using Deep Learning: Current Approaches and Open Challenges // IEEE Access. 2022. Vol. 10. PP. 66238–66266. DOI: 10.1109/access.2022.3185124. EDN: VPQSLS

10. Liu Ch., Chen Yu., Yang Sh. H. Deep Learning Based Detection for Communications Systems with Radar Interference // IEEE Transactions on Vehicular Technology. 2022. Vol. 71. Iss. 6. PP. 6245–6254. DOI: 10.1109/tvt.2022.3158692. EDN: OECFXQ

11. Соловьева Е. Б., Зубарев А. В. Нейронная модель компенсатора нелинейных искажений сигналов для цифрового канала связи // Известия высших учебных заведений России. Радиоэлектроника. 2013. № 4. С. 30–34. EDN: RUXANR

12. Малыгин И. В., Бельков С. А., Тарасов А. Д., Усвяцов М. Р. Применение методов машинного обучения для классификации радиосигналов // Труды МАИ. 2017. № 96. С. 15. EDN: ZWUHFP

13. Рапаков Г. Г., Горбунов В. А., Дианов С. В., Елизарова Л. В. Исследование LSTM-нейросетевого подхода при моделировании временных рядов // Вестник Череповецкого государственного университета. 2023. № 3 (114). С. 47–54. DOI: 10.23859/1994-0637-2023-3-114-4. EDN: AEWHEN

14. Ji S., He G., Yu Q., Shi Ya., Hu Ju., et al. A Short-Term Forecasting Method for High-Frequency Broadcast MUF Based on LSTM // Atmosphere. 2024. Vol. 15. Iss. 5. P. 569. DOI: 10.3390/atmos15050569. EDN: PSQPAQ

15. Shenvi N., Virani H. Forecasting of Ionospheric Total Electron Content Data Using Multivariate Deep LSTM Model for Different Latitudes and Solar Activity // Journal of Electrical and Computer Engineering. 2023. Vol. 2023. P. 2855762. DOI: 10.1155/2023/2855762. EDN: XUUDIO

16. Xiong P., Zhang X., Zhai D., Long C., Zhou H., et al. Long Short-Term Memory Neural Network for Ionospheric Total Electron Content Forecasting over China // Space Weather. 2021. Vol. 19. Iss. 4. P. e2020SW002706. DOI: 10.1029/2020SW002706. EDN: QHEYCE

17. Иванов М. С., Леньшин А. В. Статистические испытания методики приема и демодуляции сигналов с компенсацией неортогональных имитационных помех // Вестник Воронежского института МВД России. 2023. № 4. С. 149–158. EDN: JRLYZZ

18. Елисеев С. Н., Филимонова Л. Н. Влияние одновременного воздействия быстрых замираний и частотного сдвига в радиоканале на OFDM сигнал // V Научный форум «Телекоммуникации: теория и технологии» (ТТТ-2021). Материалы XXIII Международной научно-технической конференции «Проблемы техники и технологий телекоммуникаций» (ПТиТТ-2021, Самара, 23–26 ноября 2021 г.). 2021. С. 81–82. EDN: GAVLDS

19. Hassan H. A., Mohamed M. A., Essai M. H., Mubarak A. S., Esmail H., et al. An Efficient and Reliable OFDM Channel State Estimator Using Deep Learning Convolutional Neural Networks // Journal of Engineering Sciences. 2023. Vol. 51. Iss. 6. PP. 32–48. DOI: 10.21608/jesaun.2023.215113.1236. EDN: JCUMCA

20. Лобов Е. М., Алаа А. Обзор существующих методов коррекции межсимвольных искажений радиосигналов в цифровых системах связи с использованием машинного обучения // Телекоммуникации и информационные технологии. 2023. Т. 10. № 1. С. 109–119. EDN: MQABZM

21. Zhao R., Wang J., Li J. An End-to-End Demodulation System Based on Convolutional Neural Networks // Journal of Physics: Conference Series. 2nd International Conference on Computer Science and Communication Technology (ICCSCT, 29–31 July 2021, Beijing, China). 2021. Vol. 2026. P. 012006. DOI: 10.1088/1742-6596/2026/1/012006

22. Maranhão J. P. A., da Costa J. P. C. L., de Freitas E. P., Javidial E. Noise-Robust Multilayer Perceptron Architecture for Distributed Denial of Service Attack Detection // IEEE Communications Letters. 2020. Vol. 25. Iss. 2. PP. 402–406. DOI: 10.1109/LCOMM.2020.3032170

23. Li J., Zhang M., Xu K., Dickerson J., Ba J. How Does a Neural Network's Architecture Impact Its Robustness to Noisy Labels? // Advances in Neural Information Processing Systems. 2021. Vol. 34. DOI: 10.48550/arXiv.2012.12896

24. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А. А. Слинкина. 3-е изд., испр. и доп. М.: ДМК Пресс, 2024. 656 с.

25. Balamurugan S. P. A Comprehensive Study on MLP and CNN, and the implementation of Multi-Class Image Classification Using Deep CNN // Machine Learning and Deep Learning Techniques for Medical Science. CRC Press, 2022. PP. 1–25. DOI: 10.1201/9781003217497-1

**Статья поступила 27 ноября 2025 г.
Одобрена после рецензирования 22 декабря 2025 г.
Принята к публикации 25 декабря 2025 г.**

Информация об авторах

Исаков Михаил Владимирович – студент 2-го курса магистратуры Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича. E-mail: isakov.mv@sut.ru

Симонина Ольга Александровна – кандидат технических наук, доцент, доцент кафедры радиотехники Санкт-Петербургского государственного университета телекоммуникаций им. проф. М. А. Бонч-Бруевича. E-mail: olga.simonina@sut.ru

<https://doi.org/10.31854/2307-1303-2025-13-4-54-70>
EDN: NASEQO

Simulation of Machine Learning Methods to Improve Communication Quality in a Short-Wave Radio Channel

✉ M. Isakov, ✉ O. Simonina ✉

The Bonch-Bruевич Saint Petersburg State University of Telecommunications,
St. Petersburg, 193232, Russian Federation

Relevance. In the current conditions of telecommunications development, the shortwave band retains its significance as a cost-effective solution for long-range communication. At the same time, the existing methods of signal processing in HF channels require improvement in efficiency in the conditions of a complex ionospheric environment. The use of machine learning technologies opens up new opportunities for improving the quality of communication. **The purpose of the study** is to improve the quality of communication in the short-wave (SW) channel by applying machine learning methods for predicting ionospheric parameters and demodulating signals using OFDM technologies. **The research methods** include the simulation of LSTM-networks for predicting ionospheric parameters, as well as the application of convolutional (CNN) and multilayer perceptrons (MLP) for demodulating signals. The work uses quality metrics such as RMSE and BER, as well as ITU-R P.533-14 recommendations for modeling signal propagation conditions. **The scientific novelty** lies in a comprehensive approach to improving communication quality in the HF channel, which combines ionospheric parameter forecasting with machine learning techniques for signal demodulation. A comparative evaluation of the effectiveness of various neural network architectures in the HF channel is proposed. **The results of the study** showed that the use of CNN-demodulators provides the best signal reception quality at low SNR values, demonstrating a gain of up to 2.5 dB compared to the classical correlation method. LSTM-networks showed high efficiency in predicting the maximum applicable frequencies and other ionospheric parameters. **The practical significance of this work** is to develop methods for improving the quality of communication in the HF band, which can be used to create adaptive radio communication systems with automatic selection of operating frequencies and modulation parameters.

Keywords: short-wave communication, OFDM, machine learning, LSTM-networks, CNN, MLP, demodulation, ionosphere forecasting, communication quality

References

1. Vatruxhin E. M. New Opportunities of Using Short-Wave Radio Communication When the Aerospace Defense Tasks Are Solved by Combat Aviation // Journal of “Almaz–Antey” Air and Space Defence Corporation. 2017. Iss. 2 (21). PP. 16–20. (in Russian) EDN: YOBVLS
2. Chikhachev A. V., Budko P. A., Schmidt A. A. Application of Machine Learning Algorithms to Solve Problems of Predicting the Technical Condition of Radio Communication Facilities // Telecommunications and Communications. 2024. Iss. 3 (3). PP. 33–40. (in Russian) DOI: 10.24682/3034-4050-2024-3-33-40. EDN: IDTCNI
3. Shirokov S. Yu. Research on Influence of Artificial Intelligence for Optimization Data Transfer // Science Bulletin. 2024. Vol. 4. Iss. 12 (81). PP. 1685–1689. (in Russian) EDN: AREGOJ
4. Egorov V. V., Mingalev A. N., Shcheglova E. F. Multivariable Adaptation of HF Data Transmission Systems with OFDM Signals // Means of Communication Equipment. 2021. Iss. 3 (155). PP. 18–28. (in Russian) EDN: LYRHQF

5. Zemlyanov I. S. Modems with Orthogonal Subcarriers for Mobile Shortwave Communication Systems with Adaptation to Radio Wave Propagation Conditions. Ph. D. Thesis. Omsk, 2016. 168 p. (in Russian) EDN: NQMQRТ
6. Konkin N. A. Methodology and Algorithm for Determining the Periods of Operational Forecasting of the Maximum Usable Short Wave Communication Frequencies Based on the XGBoost Machine Learning Algorithm // Vestnik of Volga State University of Technology. Series: Radio Engineering and Infocommunication Systems. 2022. Iss. 3 (55). PP. 6–16. (in Russian) DOI: 10.25686/2306-2819.2022.3.6. EDN: ZPKQBM
7. Wang J., Shi Y., Yang C., Feng F. A Review and Prospects of Operational Frequency Selecting Techniques for HF Radio Communication // Advances in Space Research. 2022. Vol. 69. Iss. 8. PP. 2989–2999. DOI: 10.1016/j.asr.2022.01.026. EDN: GAQWAW
8. Liu X., Xu Yu., Cheng Yu., Li Ya., Zhao L. et al. A Heterogeneous Information Fusion Deep Reinforcement Learning for Intelligent Frequency Selection of HF Communication // China Communications. 2018. Vol. 15. Iss. 9. PP. 73–84. DOI: 10.1109/CC.2018.8456453
9. Oyedare T., Shah V. K., Jakubisin D. J., Reed J. H. Interference Suppression Using Deep Learning: Current Approaches and Open Challenges // IEEE Access. 2022. Vol. 10. PP. 66238–66266. DOI: 10.1109/access.2022.3185124. EDN: VPQSLS
10. Liu Ch., Chen Yu., Yang Sh. H. Deep Learning Based Detection for Communications Systems with Radar Interference // IEEE Transactions on Vehicular Technology. 2022. Vol. 71. Iss. 6. PP. 6245–6254. DOI: 10.1109/tvt.2022.3158692. EDN: OECFXQ
11. Solovyeva E. B., Zubarev A. V. Neural Model of Nonlinear Signal Distortion Compensator for Digital Communication Channel // Journal of the Russian Universities. Radioelectronics. 2013. Iss. 4. PP. 30–34. (in Russian) EDN: RUXAHR
12. Malygin I., Belkov S., Tarasov A., Usvyatsov M. Machine Learning Methods in Classification of Radio Signals // Trudy MAI. 2017. Iss. 96. P. 15. (in Russian) EDN: ZWUHFP
13. Rapakov G. G., Gorbunov V. A., Dianov S. V., Elizarova L. V. Research of the LSTM Neural Network Approach in Time Series Modeling // Cherepovets State University Bulletin. 2023. Iss. 3 (114). PP. 47–54. (in Russian) DOI: 10.23859/1994-0637-2023-3-114-4. EDN: AEWHEN
14. Ji S., He G., Yu Q., Shi Ya., Hu Ju., et al. A Short-Term Forecasting Method for High-Frequency Broadcast MUF Based on LSTM // Atmosphere. 2024. Vol. 15. Iss. 5. P. 569. DOI: 10.3390/atmos15050569. EDN: PSQPAQ
15. Shenvi N., Virani H. Forecasting of Ionospheric Total Electron Content Data Using Multivariate Deep LSTM Model for Different Latitudes and Solar Activity // Journal of Electrical and Computer Engineering. 2023. Vol. 2023. P. 2855762. DOI: 10.1155/2023/2855762. EDN: XUUDIO
16. Xiong P., Zhang X., Zhai D., Long C., Zhou H., et al. Long Short-Term Memory Neural Network for Ionospheric Total Electron Content Forecasting over China // Space Weather. 2021. Vol. 19. Iss. 4. P. e2020SW002706. DOI: 10.1029/2020SW002706. EDN: QHEYCE

17. Ivanov M. S., Lenshin A. V. Statistical Testing of Methods of Reception and Demodulation of Signals with Compensation of Non-Orthogonal Simulated Noise // Vestnik of Voronezh Institute of the Ministry of Interior of Russia. 2023. Iss. 4. PP. 149–158. (in Russian) EDN: JRLYZZ

18. Eliseev S. N., Filimonova L. N. The Effect of Simultaneous Effects of Fast Fading and Frequency Shift in the Radio Channel on the OFDM Signal // The V Scientific Forum “Telecommunications: Theory and Technology” (TTT-2021). Proceedings of the XXIII International Scientific and Technical Conference “Problems of Telecommunications Engineering and Technology” (PTETT-2021, 23–26 November 2021, Samara, Russia). 2021. PP. 81–82. (in Russian) EDN: GAVLDS

19. Hassan H. A., Mohamed M. A., Essai M. H., Mubarak A. S., Esmail H., et al. An Efficient and Reliable OFDM Channel State Estimator Using Deep Learning Convolutional Neural Networks // Journal of Engineering Sciences. 2023. Vol. 51. Iss. 6. PP. 32–48. DOI: 10.21608/jesaun.2023.215113.1236. EDN: JCUMCA

20. Lobov E. M., Alaa A. Review of Existing Methods for Correcting Inter-Symbol Distortions of Radio Signals in Digital Communication Systems Using Machine Learning // Telecommunications and Information Technologies. 2023. Vol. 10. Iss. 1. PP. 109–119. EDN: MQABZM (in Russian)

21. Zhao R., Wang J., Li J. An End-to-End Demodulation System Based on Convolutional Neural Networks // Journal of Physics: Conference Series. 2nd International Conference on Computer Science and Communication Technology (ICCSCT, 29–31 July 2021, Beijing, China). 2021. Vol. 2026. Iss. 1. P. 012006. DOI: 10.1088/1742-6596/2026/1/012006

22. Maranhão J. P. A., da Costa J. P. C. L., de Freitas E. P., Javidial E. Noise-Robust Multilayer Perceptron Architecture for Distributed Denial of Service Attack Detection // IEEE Communications Letters. 2020. Vol. 25. Iss. 2. PP. 402–406. DOI: 10.1109/LCOMM.2020.3032170

23. Li J., Zhang M., Xu K., Dickerson J., Ba J. How Does a Neural Network’s Architecture Impact Its Robustness to Noisy Labels? // Advances in Neural Information Processing Systems. 2021. Vol. 34. DOI: 10.48550/arXiv.2012.12896

24. Balamurugan S. P. A Comprehensive Study on MLP and CNN, and the implementation of Multi-Class Image Classification Using Deep CNN // Machine Learning and Deep Learning Techniques for Medical Science. CRC Press, 2022. PP. 1–25. DOI: 10.1201/9781003217497-1

Information about Authors

Isakov Michael – 2nd Year Master’s Student (The Bonch-Bruевич Saint Petersburg State University of Telecommunications). E-mail: isakov.mv@sut.ru

Simonina Olga – Ph. D. of Engineering Sciences, Associate Professor, Associate Professor at the Department of Radio Engineering (The Bonch-Bruевич Saint Petersburg State University of Telecommunications). E-mail: olga.simonina@sut.ru