

УДК 621.391.8

<https://doi.org/10.32362/2500-316X-2026-14-4-82-95>

EDN VLPBLV



НАУЧНАЯ СТАТЬЯ

Гибридная архитектура нейронной сети ResBiLSTM-BiGRU для эффективного подавления шума в радиоканале с цифровыми модулированными сигналами

В.З. Нгуен[®], Ч.Х. Фан

Вьетнамский государственный технический университет им. Ле Куй Дона, Ханой, Вьетнам

[®] Автор для переписки, e-mail: nguyenvandungvtdt@lqdtu.edu.vn

• Поступила: 24.11.2025 • Доработана: 24.01.2026 • Принята к опубликованию: 25.05.2026

Резюме

Цели. Целью данной работы является разработка эффективного метода подавления аддитивного гауссовского шума в радиоканале, обеспечивающего высокое качество восстановления цифровых модулированных сигналов при низких значениях отношения сигнал/шум (signal-to-noise ratio, SNR).

Методы. Для решения поставленной задачи предложена гибридная архитектура, объединяющая рекуррентные нейронные сети типов долгой краткосрочной памяти (long short-term memory, LSTM) и управляемых рекуррентных блоков (gated recurrent unit, GRU). Модель ResBiLSTM-BiGRU обеспечивает более стабильное обучение, повышенное качество восстановления и более точное моделирование временной структуры сигналов. Эффективность модели оценивалась на многомодуляционном наборе данных при различных уровнях входного SNR.

Результаты. Экспериментальные исследования показали, что предложенная модель в среднем обеспечивает увеличение выходного SNR на 2–3 дБ по сравнению с релятивистской усредненной генеративно-состязательной сетью (relativistic average generative adversarial networks, RaGAN) и более чем на 10 дБ по сравнению с методом на основе вейвлет-преобразования при одинаковых условиях моделирования. Модель характеризуется меньшими значениями среднеквадратической ошибки и более высокими коэффициентами корреляции во всем диапазоне входных SNR от –10 до 10 дБ. Значения пикового SNR также свидетельствуют о высоком качестве восстановления сигналов, особенно при низких уровнях входного SNR. Анализ архитектурных параметров показал, что наилучшие результаты достигаются при использовании 128 скрытых узлов и глубокой архитектуры ResBiLSTM-BiGRU.

Выводы. Полученные результаты подтверждают эффективность и практическую применимость гибридной архитектуры ResBiLSTM-BiGRU для подавления аддитивного гауссовского шума в радиоканале и восстановления цифровых модулированных сигналов, особенно в условиях низкого SNR.

Ключевые слова: когнитивные радиосети, автоматическая классификация модуляции, сигналы цифровой модуляции, глубокое обучение, гибридная сеть ResBiLSTM-BiGRU, подавление шума, отношение сигнал/шум, среднеквадратическая ошибка, коэффициент корреляции, пиковое отношение сигнал/шум

Для цитирования: Нгуен В.З., Фан Ч.Х. Гибридная архитектура нейронной сети ResBiLSTM-BiGRU для эффективного подавления шума в радиоканале с цифровыми модулированными сигналами. *Russian Technological Journal*. 2026;14(4):82–95. <https://doi.org/10.32362/2500-316X-2026-14-4-82-95>, <https://elibrary.ru/VLPBLV>

Прозрачность финансовой деятельности: Авторы не имеют финансовой заинтересованности в представленных материалах или методах.

Авторы заявляют об отсутствии конфликта интересов.

RESEARCH ARTICLE

Hybrid neural network architecture ResBiLSTM-BiGRU for efficient noise suppression in radio channels with digitally modulated signals

Nguyen Van Dung[@], Phan Trong Hanh

Le Quy Don Technical University, Hanoi, Vietnam

[@] Corresponding author, e-mail: nguyenvandungvtdt@lqdtu.edu.vn

• Submitted: 24.11.2025 • Revised: 24.01.2026 • Accepted: 25.05.2026

Abstract

Objectives. The work sets out to develop an effective method for suppressing additive Gaussian noise in radio channels to ensure the high-quality reconstruction of digitally modulated signals at low signal-to-noise ratio (SNR) levels.

Methods. To address this problem, a hybrid architecture is proposed that combines Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU) recurrent neural networks. The ResBiLSTM-BiGRU model enables more stable training and improved reconstruction quality, as well as more accurate modeling of the temporal structure of signals. The performance of the model was evaluated using a multi-modulation dataset with various input SNR levels.

Results. As confirmed by the experimental results, the proposed model achieves an average improvement of 2–3 dB in output SNR compared with the Relativistic Average Generative Adversarial Network (RaGAN) under identical simulation conditions, as well as a more than a 10-dB improvement as compared with the wavelet-transform-based method. The model is characterized by lower mean squared error values and higher correlation coefficients across the entire input SNR range from –10 to 10 dB. The peak SNR values also indicate high signal reconstruction quality, especially at low input SNR levels. Analysis of architectural parameters shows that the best performance is achieved with 128 hidden units and a deep ResBiLSTM-BiGRU architecture.

Conclusions. The obtained results confirm the effectiveness and practical applicability of the proposed ResBiLSTM-BiGRU hybrid architecture for suppressing additive Gaussian noise in radio channels and reconstructing digitally modulated signals, particularly under low-SNR conditions.

Keywords: cognitive radio networks, automatic modulation classification, digitally modulated signals, deep learning, hybrid ResBiLSTM-BiGRU network, noise suppression, signal-to-noise ratio, mean squared error, correlation coefficient, peak signal-to-noise ratio

For citation: Nguyen V.D., Phan T.H. Hybrid neural network architecture ResBiLSTM-BiGRU for efficient noise suppression in radio channels with digitally modulated signals. *Russian Technological Journal*. 2026;14(4):82–95. <https://doi.org/10.32362/2500-316X-2026-14-4-82-95>, <https://elibrary.ru/VLPBLV>

Financial disclosure: The authors have no financial or proprietary interest in any material or method mentioned.

The authors declare no conflicts of interest.

ВВЕДЕНИЕ

Современные технологии связи, включая сети 5G/6G и интернет вещей (Internet of things, IoT), создают повышенные требования к передаче сигналов высокого качества в условиях сложных и зашумленных каналов. Одной из ключевых помех является аддитивный белый гауссовский шум (additive white Gaussian noise, AWGN), который существенно снижает качество передачи сигнала и осложняет работу таких приложений, как автоматическая классификация модуляции, спектральное сенсорное восприятие и управление ресурсами в когнитивных радиосетях.

На протяжении нескольких десятилетий для подавления шума применялись традиционные методы, включая линейную фильтрацию, преобразования сигналов во временной и частотной областях, а также статистические методы [1–8]. Эти подходы показывают удовлетворительную эффективность при линейных каналах и средних или высоких значениях отношений сигнал/шум (signal to noise ratio, SNR). Однако в условиях нелинейных сигналов или низкого SNR их производительность значительно снижается, что ограничивает их практическое применение.

В последние годы глубокое обучение открыло новые перспективы для обработки радиосигналов. Модели, такие как автоэнкодеры для удаления шума (denoising autoencoder, DAE) [9, 10], генеративно-состязательные сети (generative adversarial network, GAN) [11–13], диффузионные модели (diffusion models) [14, 15] и трансформерная модель (transformer), показали возможности эффективного подавления шума. Однако каждая из этих моделей имеет ограничения: DAE теряет эффективность при низком SNR; GAN и его модификации сложны в обучении и требуют больших вычислительных ресурсов; diffusion models и transformer демонстрируют высокую производительность при сильном шуме, но с высокой вычислительной нагрузкой и задержкой вывода; отдельные сети типов долгой краткосрочной памяти (long short-term memory, LSTM) или управляемых рекуррентных блоков (gated recurrent unit, GRU) не используют полностью свой взаимодополняющий потенциал.

Исходя из этих наблюдений, в данной работе предлагается гибридная архитектура ResBiLSTM-BiGRU, объединяющая преимущества обеих моделей: LSTM обеспечивает обучение долгосрочным зависимостям, тогда как GRU обеспечивает компактность и быструю сходимость.

Основная цель исследования – разработка эффективного и практически реализуемого метода подавления AWGN в цифровых радиоканалах для систем связи нового поколения.

Основные задачи статьи включают: разработку специализированной гибридной архитектуры ResBiLSTM-BiGRU для подавления шума в цифровых радиоканалах, проведение всесторонней оценки результатов в широком диапазоне SNR (от -10 до 10 дБ) и для различных схем модуляции, демонстрацию эффективности предложенного метода по сравнению с традиционными методами подавления шума на основе показателей SNR, среднеквадратической ошибки (mean square error, MSE), корня квадратного из среднеквадратической ошибки (root mean square error, RMSE) и пикового SNR (peak signal-to-noise ratio, PSNR).

1. СВЯЗАННЫЕ РАБОТЫ

В течение нескольких десятилетий для подавления AWGN применялись как традиционные методы, так и современные подходы на основе глубокого обучения. Традиционные методы остаются популярными благодаря простоте реализации и предсказуемости, однако их эффективность снижается в сложных условиях низкого SNR или нелинейных каналов. Таблица 1 обобщает основные характеристики, преимущества и ограничения наиболее распространенных традиционных методов подавления шума.

Современные методы, основанные на глубоком обучении, демонстрируют высокую гибкость и эффективность при подавлении AWGN, особенно в условиях низкого SNR. Однако применение моделей глубокого обучения к задаче подавления шума в цифровых радиоканалах все еще сопряжено с рядом ограничений. Некоторые из существующих исследований, посвященных подавлению AWGN в цифровых модуляционных схемах, представлены в табл. 2.

Сравнительный анализ метода подавления шума на основе вейвлет-преобразования (wavelet transform, WT) и метода, основанного на релятивистской усредненной генеративно-состязательной сети (relativistic average generative adversarial networks, RaGAN), проведенный в рамках экспериментальной части работы, показывает, что при низких значениях SNR и в условиях сложного канала использование гибридной архитектуры ResBiLSTM-BiGRU демонстрирует более устойчивое качество восстановления сигнала при подавлении AWGN для различных схем модуляции.

Таблица 1. Характеристики традиционных методов шумоподавления

Группа методов	Основные методы	Основные особенности	Ограничения
Линейная фильтрация [1, 2]	Фильтрация Винера, фильтрация Калмана, адаптивный алгоритм наименьших средних квадратов (least mean squares, LMS), рекурсивный алгоритм наименьших квадратов (recursive least squares, RLS)	• фильтр Винера оптимизирует MSE в линейной среде; • фильтрация Калмана эффективна для линейных динамических систем; • LMS/RLS обеспечивает адаптивную фильтрацию для изменяющегося канала	• требуются линейные свойства сигнала и шума; • снижение эффективности при низком SNR; • ограничения при работе в нелинейных каналах или с нестационарными шумами
Подавление шума в преобразованной области [3–6]	WT, преобразование Фурье, дискретное косинусное преобразование (discrete cosine transform, DCT)	• WT обеспечивает анализ сигнала одновременно во временной и частотной областях; • преобразование Фурье и DCT представляют сигнал исключительно в частотной области; • эти методы наиболее эффективны для сигналов с выраженной и устойчивой частотной структурой	• эффективность WT зависит от выбора базисной функции и порога; • преобразование Фурье и DCT малоэффективны при AWGN; • возможна частичная потеря локальной информации
Статистические методы [7, 8]	Метод наименьшей средней квадратической ошибки (minimum mean square error, MMSE), метод максимума апостериорной вероятности (maximum a posteriori probability, MAP), метод главных компонент (principal component analysis, PCA), сингулярное разложение матрицы (singular value decomposition, SVD)	• MMSE/MAP используют вероятностные модели сигнала и шума; • PCA/SVD позволяют выделять сигнальные и шумовые компоненты; • эффективны при полном статистическом описании среды	• требуется точное знание распределений сигнала и шума; • высокая вычислительная сложность; • эффективность существенно снижается при неточной модели

Таблица 2. Характеристики методов глубокого обучения

Авторы, год, исследование	Архитектура	Данные / Канал	Основные идеи и преимущества	Ограничения
Ruifeng Duan, Ziyu Chen, Haiyan Zhang, Xu Wang, Wei Meng, Guodong Sun, 2023 [10]	Автоэнкодер с остаточными связями и механизмом внимания к каналам	Цифровые модулированные сигналы; AWGN	Комбинация двух остаточных соединений в сети энкодер-декодер и усовершенствованного модуля SE-ResNet ¹ для усиления способности извлечения признаков и снижения вычислительной сложности	Сравнение только с RLS, LMS, PCA
Shoushuai He, Lei Zhu, Changhua Yao, Lei Wang, Zhen Qin, 2022 [11]	Модифицированная архитектура GAN	Цифровые модулированные сигналы; AWGN + интерференция	Восстановление деталей лучше традиционных фильтров	Сложность обучения, трудности настройки
Liang Peng, Shengliang Fang, Youchen Fan, Mengtao Wang, Zhao Ma, 2023 [12]	RaGAN	Цифровые модулированные сигналы; AWGN	Использование GAN для генерации чистого сигнала из зашумленного, повышение качества восстановления по сравнению с традиционными фильтрами	Сложность обучения, высокая вычислительная нагрузка

¹ Squeeze-and-Excitation ResNet (SE-ResNet) – архитектура сверточных нейронных сетей, объединяющая остаточные связи ResNet с механизмом канального внимания на основе блоков Squeeze-and-Excitation, позволяющим адаптивно перекалибровать каналы признаков путем моделирования их взаимозависимостей. [The Squeeze-and-Excitation Residual Network (SE-ResNet) is a convolutional neural network architecture combining the skip connections of ResNet with a channel-wise attention mechanism based on Squeeze-and-Excitation blocks. This enables the adaptive recalibration of feature channels by modeling their mutual dependencies.]

Таблица 2. Продолжение

Авторы, год, исследование	Архитектура	Данные / Канал	Основные идеи и преимущества	Ограничения
Tong Wu, Zhiyong Chen, Dazhi He, Liang Qian, Yin Xu, Meixia Tao, Wenjun Zhang, 2023 [14]	Модель диффузии используется для прогнозирования и подавления шума после выравнивания канала	Канал связи Релея и AWGN	Определяет процесс диффузии по условному распределению принимаемого сигнала, может интегрироваться как модуль подавления шума для повышения качества сигнала	Высокая вычислительная сложность
Zelin Ji, Shuo Wang, Kuojun Yang, Qinchuan Zhang, Peng Ye, 2024 [16]	GRU-модуль подавления шума с классификатором	Циклический сигнал; цифровой модулированный сигнал; канал AWGN	Предварительное обучение шумоподавителя на циклическом сигнале с последующей донастройкой (fine-tuning) на цифровом модулированном сигнале; повышение точности более чем на 20% при низких значениях SNR	Ограниченный набор модуляций; не проведена оценка с использованием чистых метрик подавления шума (MSE/SNR)

2. ПРЕДЛАГАЕМЫЙ МЕТОД

2.1. Архитектура сети ResBiLSTM-BiGRU для подавления аддитивного гауссовского шума и компенсации неидеального канала передачи базовых I/Q-данных²

В данной статье предполагается, что принимаемые данные представляют собой базовые I/Q-данные, переданные по каналу связи и искаженные аддитивным гауссовским шумом. Для построения эффективной модели подавления шума для сигналов такого типа предлагается архитектура типа ResNet³, названная ResBiLSTM-BiGRU, в которой обучаемая ветвь представляет собой гибридную архитектуру, включающую каскадное соединение LSTM и GRU.

Перед описанием архитектуры гибридной сети приведем сравнительный анализ ключевых характеристик LSTM и GRU [17]. В табл. 3 представлены их основные различия.

Общая архитектура сети ResBiLSTM-BiGRU представлена на рис. 1. Как видно, предлагаемая сеть имеет структуру ResNet и включает две параллельные ветви. Правая ветвь представляет собой прямое соединение и выполняет функцию основного потока данных, обеспечивая стабилизацию передачи информации и предотвращение затухания или взрыва градиента во всей сети. Левая ветвь является обучаемой и реализует гибридную архитектуру LSTM-GRU совместно со вспомогательными слоями (далее – Hybrid LSTM-GRU).

² I – in-phase, синфазный компонент, Q – quadrature, квадратурный компонент – две ортогональные компоненты комплексного сигнала. [I stands for the in-phase component, Q stands for the quadrature component, and the quadrature component refers to two orthogonal components of a complex signal.]

³ Residual networks – архитектура сверточных нейронных сетей, использующая остаточные связи (skip connections). [A residual network is an architecture for convolutional neural networks that uses skip connections.]

Таблица 3. Сравнительные характеристики архитектур LSTM и GRU

Характеристика	LSTM	GRU
Количество ворот (gates)	Три: вход, забывание, выход	Два: обновление, сброс
Количество состояний	Два: состояние ячейки и скрытое состояние	Одно: скрытое состояние
Механизм памяти	Линейное перенесение информации через состояние ячейки, устойчивое к долгим зависимостям	Слияние новой и предыдущей информации в скрытом состоянии, эффективное для средних и коротких зависимостей
Сложность модели	Более высокая	Более низкая
Число параметров	Значительно больше	Меньше (на 25–30% по сравнению с LSTM)
Скорость обучения	Ниже	Выше
Моделирование долгосрочных зависимостей	Очень высокое	Высокое, но уступает LSTM
Моделирование кратковременной динамики	Менее чувствительное	Более чувствительное
Склонность к переобучению	Выше	Ниже
Затраты памяти	Выше	Ниже
Характер сходимости	Медленнее, чувствительно к гиперпараметрам	Быстрее и стабильнее
Типовые приложения	Длинные последовательности, сигналы с трендом или дрейфом	Зашумленные сигналы, обработка в реальном времени, ограниченные ресурсы

Входом сети является базовый I/Q-сигнал, искаженный аддитивным гауссовским шумом, представленный в виде тензора размерности $[B, T, 2]$, где B – размер батча, T – длина временной последовательности, а значение 2 соответствует двум каналам I и Q. Поскольку правая ветвь является прямым соединением, далее подробно рассматривается только обработка данных в ветви Hybrid LSTM-GRU.

На первом этапе данные обрабатываются двунаправленными слоями LSTM (BiLSTM) для извлечения временных зависимостей в обоих направлениях, а также для запоминания долгосрочных корреляций данных. Далее сигнал с выхода LSTM подается на двунаправленные слои GRU (BiGRU) для уточнения признаков и запоминания локальных зависимостей с более высокой скоростью обновления и меньшими вычислительными затратами благодаря упрощенной структуре вентиляей.

Затем выходные данные GRU нормализуются с помощью нормализации слоя (layer normalization) для стабилизации процесса обучения и подаются на линейный слой для согласования размерности с ветвью прямой передачи. На заключительном этапе данные суммируются с выходными данными прямого соединения, формируя итоговый выходной сигнал сети.

Целью структуры, показанной на рис. 1, является подавление аддитивного гауссовского шума и компенсация искажений, обусловленных неидеальностью канала передачи, влияющих на принимаемый сигнал.

2.2. Обоснование целесообразности структуры Hybrid LSTM-GRU

Как показано на рис. 1, наиболее важной частью предлагаемой модели является гибридная архитектура, объединяющая LSTM и GRU (Hybrid LSTM-GRU). Более подробное представление данной архитектуры приведено на рис. 2.




Рис. 1. Архитектура гибридной сети ResBiLSTM-BiGRU для подавления шума в смеси с сигналом цифровой модуляции

Сеть, представленная на рис. 2, работает с базовыми I/Q-данными, представляющими собой модулированный сигнал, приведенный к базовой полосе частот и содержащий информацию об амплитудной, частотной и фазовой модуляции. При передаче по каналу сигнал подвергается воздействию аддитивного шума и может быть смоделирован следующим образом:

$$x(n) = A(n)e^{j\phi} + \eta(n), \quad (1)$$

где $A(n)$ и $\phi(n)$ – медленно изменяющиеся компоненты, несущие информацию о модуляции, взаимосвязи между символами, а также информацию о канале передачи, включая эффекты многолучевости и замирания, а $\eta(n)$ – аддитивный шум, который в общем случае моделируется как белый гауссовский процесс.




Рис. 2. Структура последовательной гибридной архитектуры LSTM-GRU. $x(n)$ – зашумленный сигнал, $s(n)$ – чистый сигнал; $\hat{s}(n)$ – восстановленный сигнал; h_t^L, h_t^G – скрытые состояния LSTM и GRU соответственно; θ_L – параметры LSTM; $F(x)$ описывает преобразование входного сигнала сетью, итоговый выход формируется с использованием остаточной связи: $\hat{s}(n) = x(n) + F(x)$; $\mathcal{L}$ – функция потерь; G_L – градиент функции потерь; n – номер отсчета; t – временной шаг

В такой постановке задачи обработка I/Q-данных заключается не только в подавлении аддитивного шума $\eta(n)$, но и в выявлении характерных структур сигнала (signal patterns), а также эффектов многолучевости и замираний (effects of multipath/fading), содержащихся в $A(n)$ и $\phi(n)$. Во временной области AWGN $\eta(n)$ является быстроизменяющейся компонентой (несущей краткосрочную информацию), тогда как структура сигнала и многолучевость/замирение относятся к медленно изменяющимся компонентам (несущим долгосрочную информацию). Иными словами, сигнал $x(n)$ в формуле (1) обладает многошкальной временной структурой.

Математическая модель I/Q-данных, представленная в формуле (1), и проведенный выше анализ непосредственно обуславливают структуру сети, показанную на рис. 2. Базовые I/Q-данные обладают многошкальной временной структурой и, более того, могут рассматриваться как статистически независимые в том смысле, что белый гауссовский шум некоррелирован с остальными компонентами. В процессе обучения архитектура, представленная на рис. 2, позволяет LSTM преимущественно запоминать долгосрочные компоненты, тогда как GRU специализируется на моделировании краткосрочных. С физической точки зрения LSTM ориентирована на извлечение характерных структур сигнала и эффектов многолучевости/замираний, в то время как GRU преимущественно выделяет информацию, связанную с аддитивным белым шумом.

Таким образом, многошкальная временная структура и статистическая независимость компонентов I/Q-сигналов формируют естественную предпосылку для того, чтобы гибридная сеть автоматически распределяла роли между LSTM и GRU без введения априорных ограничений.

2.3. Набор данных

В данном исследовании используется открытый набор данных DeepSig⁴: RadioML 2018.01A [18], широко применяемый для задач распознавания модуляции радиосигналов. Набор включает 24 вида модуляции, каждая из которых представлена на 26 уровнях SNR в диапазоне от -20 до $+30$ дБ с шагом 2 дБ. Для каждой пары «модуляция – SNR» доступно 4096 фреймов, и каждый фрейм содержит 1024 отсчета комплексного сигнала, представленного в виде компонент I/Q размерности (1024, 2). Общий объем набора данных составляет 2555904 фрейма.

Для адаптации набора данных к задаче подавления шума были выделены сигналы с SNR = 30 дБ, которые рассматриваются как эталонные «чистые»

сигналы с минимальным уровнем шума. На их основе формировался зашумленный набор, где к каждому сигналу добавлялся AWGN на уровнях SNR от -10 до $+10$ дБ с шагом 2 дБ согласно гауссовскому распределению. Таким образом, были сформированы два поднабора: чистые модулированные сигналы и зашумленные модулированные сигналы.

Основные параметры набора данных приведены в табл. 4.

Таблица 4. Основные параметры набора данных

Параметр	Значение
Виды модуляции	8 видов: BPSK ⁵ , QPSK ⁶ , OQPSK ⁷ , 8PSK ⁸ , 16QAM ⁹ , 64QAM ¹⁰ , GMSK ¹¹ , OOK ¹²
Диапазон SNR	11 значений: от -10 до 10 дБ с шагом 2 дБ
Число отсчетов в одном фрейме	1024
Число фреймов на одну пару «модуляция – SNR»	4096
Формат данных во фрейме	1024 комплексных отсчета I/Q (синфазная и квадратурная компоненты), размер (1024, 2)
Общее число фреймов	360448 фреймов ($8 \times 11 \times 4096$)
Канал связи	AWGN

Набор данных был разделен на обучающую, валидационную и тестовую части в пропорции 80% – 10% – 10%. Обучающая и валидационная части использовались для обучения предлагаемой гибридной модели LSTM-GRU и модели RaGAN, тогда как тестовая выборка предназначена для сравнения их эффективности, а также оценки производительности методов подавления шума на основе WT.

⁵ Binary Phase Shift Keying – двоичная фазовая манипуляция.

⁶ Quadrature Phase Shift Keying – квадратурная фазовая манипуляция.

⁷ Offset Quadrature Phase Shift Keying – квадратурная фазовая манипуляция со смещением.

⁸ 8-Phase Shift Keying – восьмипозиционная фазовая манипуляция.

⁹ 16-Quadrature Amplitude Modulation – 16-позиционная квадратурная амплитудная модуляция.

¹⁰ 64-Quadrature Amplitude Modulation – 64-позиционная квадратурная амплитудная модуляция.

¹¹ Gaussian Minimum Shift Keying – гауссовская манипуляция с минимальным сдвигом частоты.

¹² On-Off Keying – амплитудная манипуляция «включено-выключено».

⁴ <https://www.deepsig.ai/datasets/>. Дата обращения 24.11.2025. / Accessed November 11, 2025.

3. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

Для оценки эффективности предложенной гибридной архитектуры ResBiLSTM-BiGRU проведены эксперименты на тестовой выборке. Производительность модели сравнивалась с двумя репрезентативными методами: глубокой моделью RaGAN и традиционным методом подавления шума на основе WT.

Модель RaGAN использует генеративно-сопоставительную сеть с релятивистским дискриминатором, построенную на основе двунаправленных LSTM (Bi-LSTM). Обозначим чистый (реальный, real) сигнал как s_r , а сгенерированный (fake) сигнал – как s_f . Дискриминатор оценивает вероятность того, что реальные данные более реалистичны по сравнению со сгенерированными, а функции потерь дискриминатора (D) и генератора (G) задаются следующим образом:

$$L_D^{\text{Ra}} = -E \left[\log \left(D_{\text{RaGAN}}(s_r, s_f) \right) \right] - E \left[\log \left(1 - D_{\text{RaGAN}}(s_f, s_r) \right) \right],$$

$$L_G^{\text{Ra}} = -E \left[\log \left(1 - D_{\text{RaGAN}}(s_r, s_f) \right) \right] - E \left[\log \left(D_{\text{RaGAN}}(s_f, s_r) \right) \right],$$

где $E[\cdot]$ обозначает математическое ожидание, а D_{RaGAN} – релятивистский дискриминатор, используемый в модели RaGAN.

Для повышения качества восстановления чистого сигнала общий функционал потерь генератора формируется как взвешенная сумма контентной потери и сопоставительной потери:

$$L_G = L_{\text{con}} + \lambda L_G^{\text{Ra}},$$

где λ – коэффициент балансировки. Контентная потеря основана на MSE и абсолютной разности:

$$L_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n \left(s_{r_i} - G(s_f)_i \right)^2, \quad L_1 = \frac{1}{n} \sum_{i=1}^n \left| s_{r_i} - G(s_f)_i \right|,$$

$$L_{\text{con}} = \frac{L_{\text{MSE}} + L_1}{2}.$$

Такое сочетание потерь позволяет генератору более точно восстанавливать зашумленный сигнал, учитывая качество контента и сопоставительную составляющую.

Классический метод WT работает в частотной области. Зашумленный сигнал $y(t)$ разлагается в набор вейвлет-коэффициентов:

$$c_{j,k} = \int y(t) \psi_{j,k}(t) dt,$$

где $\psi_{j,k}(t)$ – базисные вейвлет-функции на масштабе j и позиции k . Далее применяют пороговую фильтрацию коэффициентов:

$$\tilde{c}_{j,k} = \begin{cases} \text{sign}(c_{j,k}) \left(|c_{j,k}| - \lambda \right), & |c_{j,k}| > \lambda, \\ 0, & |c_{j,k}| \leq \lambda, \end{cases}$$

после чего сигнал восстанавливается обратным WT:

$$\hat{x}(t) = \sum_{j,k} \tilde{c}_{j,k} \psi_{j,k}(t).$$

Такой подход позволяет удалять шумовые высокочастотные компоненты за счет порогового обнуления соответствующих коэффициентов.

Эффективность подавления шума оценивалась по стандартным метрикам качества восстановления, включая MSE, SNR, коэффициент корреляции (correlation coefficient, CC) и PSNR. Формулы для расчета этих метрик приведены в табл. 5.

Таблица 5. Метрики для оценки качества подавления шума

Метрика	Формула
Отношение сигнал/шум (SNR)	$\text{SNR} = 10 \cdot \lg \left(\frac{\sum_{i=1}^N x_i^2}{\sum_{i=1}^N (x_i - \hat{x}_i)^2} \right) \text{ дБ},$ где x – исходный чистый сигнал, $\hat{x}$ – восстановленный сигнал, N – количество отсчетов
Среднеквадратическая ошибка (MSE)	$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2$
Коэффициент корреляции (CC)	$\text{CC} = \frac{\sum_{i=1}^N (x_i - \bar{x})(\hat{x}_i - \bar{\hat{x}})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (\hat{x}_i - \bar{\hat{x}})^2}},$ где $\bar{x}$ – средние значения исходного чистого сигнала, $\bar{\hat{x}}$ – средние значения восстановленного сигнала
Пиковое отношение сигнал/шум (PSNR)	$\text{PSNR} = 10 \cdot \lg \frac{x_{\text{max}}^2}{\text{MSE}}.$ Параметр x_{max} определяется как максимальное амплитудное значение чистого одномерного сигнала, вычисляемое по его дискретной временной реализации в тестовой выборке

Модель обучалась с использованием функции потерь MSE и оптимизатора Adam¹³ в течение 150 эпох. В процессе обучения применялся механизм адаптивного уменьшения скорости обучения (reduce

¹³ Adaptive moment estimation (адаптивная оценка момента) – алгоритм оптимизации, используемый для обучения нейронных сетей, который объединяет идеи метода импульса и адаптивного масштабирования градиента. [Adaptive moment estimation is an optimization algorithm used for training neural networks that combines the concepts of the momentum method and adaptive gradient scaling.]

learning rate on plateau, ReduceLROnPlateau), при котором значение темпа обучения (learning rate) снижалось при отсутствии улучшения метрики на протяжении пяти последовательных эпох. Для предотвращения переобучения и сокращения времени вычислений также использовалась стратегия early stopping¹⁴, срабатывающая при остановке уменьшения функции потерь. Результаты обучения, представленные на рис. 3, демонстрируют стабильное снижение функции потерь на обучающей и тестовой выборках, а также достижение модели устойчивых и оптимальных значений ошибки.




Рис. 3. Значения обучающих и валидационных потерь в процессе обучения

На рис. 4а представлены результаты сравнения по метрике SNR между различными методами подавления шума. Предлагаемая модель демонстрирует наилучшую производительность на всем диапазоне входных значений SNR от -10 до $+10$ дБ. В сравнении с RaGAN среднее улучшение составляет около 2.27 дБ. При очень низком уровне SNR (-10 дБ) прирост достигает лишь 0.41 дБ, однако затем постепенно увеличивается и стабилизируется в пределах 3.0–3.5 дБ на высоких значениях SNR. По сравнению с WT преимущество еще более заметно: среднее улучшение составляет 10.5 дБ. В области низких SNR (от -10 до 0 дБ) улучшение варьируется в диапазоне 6.1–12.3 дБ, а в области высоких SNR (от 2 до 10 дБ) удерживается на уровне 11–13.5 дБ.

На рис. 4б приведены результаты сравнения средних значений MSE. Предлагаемая модель стабильно обеспечивает минимальное значение MSE,

демонстрируя более точное восстановление сигнала по сравнению с RaGAN и WT. Особенно значительное улучшение наблюдается по сравнению с WT: при SNR = -10 дБ MSE составляет 0.2556, тогда как у WT — 1.077, а при 10 дБ снижается до 0.0024, в то время как WT остается на уровне 0.0233 (почти в 10 раз хуже). В сравнении с RaGAN разница менее выражена, но сохраняется на всем диапазоне SNR. Например, при -10 дБ MSE модели составляет 0.255 против 0.279 у RaGAN, а при 10 дБ — 0.0024 против 0.0042 (примерно в 1.7 раза лучше).

На рис. 4в представлено сравнение коэффициента корреляции между исходным и восстановленным сигналами. Предлагаемая модель достигает наивысших значений на всем диапазоне SNR, что подтверждает ее лучшую способность сохранять временную структуру сигнала. При SNR = -10 дБ коэффициент корреляции составляет 0.726, что выше результата RaGAN (0.718) и почти вдвое превышает значение WT (0.366). По мере увеличения SNR показатели всех моделей улучшаются, однако предлагаемая модель сохраняет устойчивое преимущество. При SNR = 0 дБ коэффициент корреляции достигает 0.980, что выше соответствующих значений, полученных для RaGAN (0.971) и WT (0.822). На высоких уровнях SNR (≥ 6 дБ) все методы приближаются к области насыщения (более 0.99 для предлагаемой модели и RaGAN), однако предлагаемая модель по-прежнему демонстрирует лучшие результаты, тогда как WT заметно отстает (0.979 при 10 дБ против 0.998 у предлагаемой модели).

На рис. 4г представлены результаты сравнения величины PSNR. Предлагаемая модель демонстрирует максимальные значения PSNR по всему диапазону SNR, что подтверждает ее высокую способность к восстановлению сигнала. При SNR = -10 дБ значение PSNR составляет 11.72 дБ, что выше соответствующих значений, полученных для RaGAN (11.31 дБ) и WT (3.47 дБ). По мере увеличения SNR разница между предлагаемой моделью и RaGAN остается стабильной — примерно 2–3 дБ. По сравнению с WT преимущество особенно заметно: при 0 дБ PSNR составляет 25.38 дБ против 10.89 дБ у WT; при 10 дБ модель достигает 33.93 дБ, что почти на 14 дБ выше WT (20.06 дБ).

Влияние количества скрытых узлов в гибридной архитектуре ResBiLSTM-BiGRU представлено на рис. 5а. Увеличение числа узлов с 32 до 64 приводит к заметному росту качества восстановления сигнала: например, при SNR = 0 дБ значение метрики возрастает с 14.54 до 15.59 дБ. Дальнейшее увеличение до 128 узлов обеспечивает оптимальную производительность: при 0 дБ показатель достигает 17.07 дБ, что на 1.5 дБ выше относительно конфигурации с 64 узлами и на 2.5 дБ выше по сравнению с 32 узлами. Однако при 256 узлах улучшение не наблюдается: производительность сопоставима с конфигурацией 64 узла

¹⁴ Early stopping (ранняя остановка) — метод регуляризации, при котором процесс обучения нейронной сети прерывается, когда ошибка на валидационных данных перестает уменьшаться (и, как правило, начинает расти), что позволяет предотвратить переобучение (overfitting). [Early stopping is a regularization method in which the learning process of a neural network is interrupted when the error on the validation data stops decreasing (and usually begins to increase), which prevents overfitting.]




Рис. 4. Результаты сравнения методов подавления шума: (а) выходное SNR, (б) MSE, (в) коэффициент корреляции, (г) PSNR




Рис. 5. Результаты сравнения методов подавления шума по: (а) количеству скрытых узлов, (б) значению dropout

и остается ниже, чем у варианта с 128 узлами, на всем диапазоне SNR. Эти результаты подтверждают, что использование 128 скрытых узлов является наиболее эффективным выбором с учетом баланса между качеством восстановления и сложностью модели.

На рис. 5б показано влияние коэффициента dropout¹⁵ на производительность. В отсутствие dropout модель демонстрирует максимальную эффективность.

При значении dropout = 0.2 наблюдается лишь небольшое снижение качества восстановления, при этом общая стабильность модели сохраняется. Увеличение dropout до 0.5 приводит к существенному снижению производительности на всем диапазоне SNR.

На рис. 6 представлены результаты сравнения различных вариантов комбинации блоков LSTM и GRU. Использование только LSTM обеспечивает

¹⁵ Гиперпараметр метода регуляризации нейронных сетей, определяющий вероятность случайного исключения нейронов в процессе обучения для предотвращения переобучения. [A hyperparameter of the neural network regularization method that determines the probability of unintentional pruning of neurons during the training process in order to prevent overfitting.]

ограниченную производительность (например, 13.33 дБ при SNR = 0 дБ). Добавление блока GRU (конфигурация LSTM-GRU) значительно повышает качество восстановления сигнала, достигая 16.08 дБ при 0 дБ. Более глубокая архитектура LSTM2-GRU2 с остаточным соединением (ResBiLSTM-BiGRU) демонстрирует наилучшие показатели: 17.07 дБ при 0 дБ и 25.62 дБ при 10 дБ – это максимальные значения среди всех рассмотренных конфигураций. Варианты LSTM-GRU-STM-GRU и LSTM2-GRU2 без остаточных соединений также обеспечивают высокую производительность, однако уступают архитектуре LSTM2-GRU2-Res как по стабильности, так и по абсолютным значениям метрики на всем диапазоне SNR.

На рис. 7 показаны результаты работы предлагаемого метода для восьми видов модуляции: BPSK, QPSK, OQPSK, 8PSK, 16QAM, 64QAM, GMSK и OOK. На низких входных SNR наименьшую эффективность показывают 64QAM, 16QAM и 8PSK – у них ниже выходное SNR, PSNR и коэффициент корреляции, а MSE – выше. BPSK, GMSK и OOK демонстрируют лучшие результаты при тех же условиях. При увеличении SNR различия между модуляциями уменьшаются, однако высокие порядки QAM и 8PSK продолжают показывать чуть меньшую эффективность.




Рис. 6. Результаты сравнения производительности различных вариантов гибридной архитектуры LSTM-GRU

Некоторые примеры сравнения сигналов во временной области при различных уровнях SNR после применения методов подавления шума приведены на рис. 8.




Рис. 7. Результаты оценки качества предлагаемого метода для восьми видов модуляции: BPSK, QPSK, OQPSK, 8PSK, 16QAM, 64QAM, GMSK и OOK при различных входных уровнях SNR: (а) выходное SNR, (б) MSE, (в) PSNR, (г) коэффициент корреляции




Рис. 8. Сигналы после подавления шума различными моделями для модулированного сигнала:
(а) 16QAM при SNR = -6 дБ, (б) BPSK при SNR = 0 дБ

ЗАКЛЮЧЕНИЕ

В данной работе предложена гибридная архитектура ResBiLSTM-BiGRU для задачи подавления шума в смеси с сигналами цифровой модуляции в канале AWGN. Экспериментальные результаты показали, что предлагаемая модель обеспечивает среднее улучшение восстанавливаемого SNR на 2–3 дБ по сравнению с RaGAN и более чем на 10 дБ по сравнению с WT, а также демонстрирует наименьшие значения MSE и наибольшие коэффициенты корреляции на всем диапазоне входных SNR от –10 до 10 дБ. Значения PSNR дополнительно подтверждают высокую способность модели к восстановлению сигнала, особенно при низких уровнях SNR.

Анализ параметров показал, что конфигурация с 128 скрытыми узлами является оптимальной;

увеличение значения dropout приводит к заметному снижению качества, а наивысшую эффективность среди исследованных вариантов обеспечивает глубокая архитектура ResBiLSTM-BiGRU. Полученные результаты подтверждают эффективность и перспективность гибридной модели ResBiLSTM-BiGRU в задачах подавления аддитивного гауссовского шума.

В дальнейшем планируется исследовать возможность интеграции модуля подавления шума непосредственно с системой автоматической классификации модуляции для повышения эффективности всей радиосистемы.

Вклад авторов

Все авторы в равной степени внесли свой вклад в исследовательскую работу.

Authors' contribution

All authors contributed equally to the research work.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Wang W. Evaluation of Adaptive Filtering Algorithms in Signal Denoising: Insights from Simulation and Algorithmic Enhancement. *Theoretical and Natural Science*. 2025;101(1):61–69. <https://doi.org/10.54254/2753-8818/2025.CH22293>
2. Lei J., Zhou J., Jian Z., Liu H., Zhang L., Feng Y., Wu Z. A Wiener Filter Denoising Based Intelligent Modulation Recognition. In: *2022 IEEE/CIC International Conference on Communications in China (ICCC)*. IEEE. 2022. P. 88–93. <https://doi.org/10.1109/ICCC55456.2022.9880789>
3. Guo T., Zhang T., Lim E., López-Benítez M., Ma F., Yu L. A Review of Wavelet Analysis and Its Applications: Challenges and Opportunities. *IEEE Access*. 2022;10:58869–58903. <https://doi.org/10.1109/ACCESS.2022.3179517>
4. Akkaya S. Wavelet-Based Denoising Strategies for Non-Stationary Signals in Electrical Power Systems: An Optimization Perspective. *Electronics*. 2025;14(16):3190. <https://doi.org/10.3390/electronics14163190>
5. Facciolo G., Pierazzo N., Morel J.-M. Conservative Scale Recomposition for Multiscale Denoising. (The Devil is in the High Frequency Detail). *SIAM J. Imaging Sci.* 2017;10(3):1603–1626. <https://doi.org/10.1137/17M1111826>
6. Wahab M.F., Gritti F., C. O'Haver T. Discrete Fourier transform techniques for noise reduction and digital enhancement of analytical signals. *TrAC Trends in Analytical Chemistry*. 2021;143(4):116354. <https://doi.org/10.1016/j.trac.2021.116354>
7. Zhao S., Ma L., Xu L., Liu M., Chen X. A Study of Fault Signal Noise Reduction Based on Improved CEEMDAN-SVD. *Appl. Sci.* 2023;13(19):10713. <https://doi.org/10.3390/app131910713>
8. Wang H., Yao Y., Zhang G., Pan J., Gao L., Jin H., Wang C. Enhanced Noise Suppression in Partial Discharge Signals via SVD and VMD with Wavelet Thresholding. *Modelling and Simulation in Engineering*. 2024;2024:5676986. <https://doi.org/10.1155/2024/5676986>
9. Almazrouei E., Gianini G., Almoosa N., Damiani E. A Deep Learning Approach to Radio Signal Denoising. In: *2019 IEEE Wireless Communications and Networking Conference Workshop (WCNCW)*. IEEE. 2019. <https://doi.org/10.1109/WCNCW.2019.8902756>
10. Duan R., Chen Z., Zhang H., Wang X., Meng W., Sun G. Dual Residual Denoising Autoencoder with Channel Attention Mechanism for Modulation of Signals. *Sensors*. 2023;23(2):1023. <https://doi.org/10.3390/s23021023>
11. He S., Zhu L., Yao C., Wang L., Qin Z. A Novel Approach Based on Generative Adversarial Network for Signal Enhancement in Wireless Communications. *Wireless Communications and Mobile Computing*. 2022. <https://doi.org/10.1155/2022/7050573>
12. Peng L., Fang S., Fan Y., Wang M., Ma Z. A Method of Noise Reduction for Radio Communication Signal Based on RaGAN. *Sensors*. 2023;23(1):475. <https://doi.org/10.3390/s23010475>
13. Yao H., Zhou Q., Chen Z., Huang L., Xu D., Xuan Q. Denoising of Radio Modulation Signal Based on Deep Learning. In: Xuan Q., Xiang Y., Xu D. (Eds.). *Deep Learning Applications*. 2023. Ch. 7. P. 125–143. https://doi.org/10.1142/9789811266911_0007
14. Wu T., Chen Z., He D., Qian L., Xu Y., Tao M. CDDM: Channel Denoising Diffusion Models for Wireless Semantic Communications. *IEEE Trans. on Wireless Commun.* 2024;23(9):11168–11183. <https://doi.org/10.1109/TWC.2024.3379244>
15. Letafati M., Ali S., Latva-Aho M. Conditional Denoising Diffusion Probabilistic Models for Data Reconstruction Enhancement in Wireless Communications. *IEEE Trans. on Machine Learning in Communications and Networking*. 2025;3:133–146. <https://doi.org/10.1109/TMLCN.2024.3522872>
16. Ji Z., Wang S., Yang K., Zhang Q., Ye P. Transfer Learning Guided Noise Reduction for Automatic Modulation Classification. In: *2025 IEEE 102nd Vehicular Technology Conference (VTC2025-Fall)*. IEEE. 2025. <https://doi.org/10.1109/VTC2025-Fall65116.2025.11310099>

17. Chung J., Gulcehre C., Cho K.H., Bengio Y. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv preprint*. arXiv:1412.3555. 2014. <http://arxiv.org/abs/1412.3555>
18. O'Shea T.J., Roy T., Clancy T.C. Over-the-Air Deep Learning Based Radio Signal Classification. *IEEE J. Selected Topics in Signal Process.* 2018;12(1):168–179. <https://doi.org/10.1109/JSTSP.2018.2797022>

Об авторах

Нгуен Ван Зунг, к.т.н., преподаватель, кафедра теории цепей – измерения, Факультет радиотехники и электроники, Вьетнамский государственный технический университет им. Ле Куй Дона (Вьетнам, Ханой, ул. Хоанг Куок Вьет, д. 236). E-mail: nguyenvandungvtdt@lqdtu.edu.vn. <https://orcid.org/0000-0002-2810-1204>

Фан Чонг Хань, к.т.н., преподаватель, кафедра теории цепей – измерения, Факультет радиотехники и электроники, Вьетнамский государственный технический университет им. Ле Куй Дона (Вьетнам, Ханой, ул. Хоанг Куок Вьет, д. 236). E-mail: maitrongphan@gmail.com. <https://orcid.org/0009-0006-2093-7150>

About the Authors

Nguyen Van Dung, Cand. Sci. (Eng.), Lecturer, Department of Circuit Theory – Measurement, Faculty of Radio-Electronic Engineering, Le Quy Don Technical University (236, Hoang Quoc Viet, Ha Noi, Viet Nam). E-mail: nguyenvandungvtdt@lqdtu.edu.vn. <https://orcid.org/0000-0002-2810-1204>

Phan Trong Hanh, Cand. Sci. (Eng.), Lecturer, Department of Circuit Theory – Measurement, Faculty of Radio-Electronic Engineering, Le Quy Don Technical University (236, Hoang Quoc Viet, Ha Noi, Viet Nam). E-mail: maitrongphan@gmail.com. <https://orcid.org/0009-0006-2093-7150>