

УДК 004.032.26

DOI:10.25729/ESI.2025.39.3.003

Разработка архитектуры нейронной сети для восстановления радиосигнала с БПЛА

Фелагерова Евгения Юрьевна¹, Рудоман Нэлли Радиковна¹,
Кузякина Марина Викторовна^{1,2}

¹Кубанский государственный университет,
Россия, Краснодар, efelagereva@gmail.com

²Кубанский государственный технологический университет,
Россия, Краснодар

Аннотация. В представленном исследовании рассматривается проблема применения классических методов восстановления радиосигнала. В качестве решения предлагается использование нейронных сетей, а именно автокодировщиков. Разработана архитектура вариационного автоэнкодера для решения задачи восстановления радиосигнала с беспилотного летательного аппарата. Для обучения и проверки модели был использован большой датасет, содержащий радиосигналы различных видов модуляций и уровней шума, DeepSig Dataset: RadioML 2018.01A. Целью исследования является разработка архитектуры, показывающей наиболее лучшие метрики восстановления радиосигналов, чем классические методы. В качестве метрик качества используются PSNR, MSE и MAE, а оптимизатор Adam. Также к датасету был применен фильтр Калмана, показавший результат на два порядка хуже по всем метрикам качества. Полученные данные показывают, что не всегда классические алгоритмы восстановления искаженных радиосигналов могут показывать достойное качество работы.

Ключевые слова: вариационный автоэнкодер, радиосигнал, БПЛА, фильтр Калмана

Цитирование: Фелагерова Е.Ю. Разработка архитектуры нейронной сети для восстановления радиосигнала с БПЛА / Е.Ю. Фелагерова, Н.Р. Рудоман, М.В. Кузякина // Информационные и математические технологии в науке и управлении, 2025. – № 3 (39). – С. 26-38. – DOI:10.25729/ESI.2025.39.3.003.

Введение. Современные беспилотные летательные аппараты (БПЛА) активно применяются в самых различных сферах, включая связь, мониторинг окружающей среды, разведку и навигацию. Важными аспектами их функционирования являются передача и обработка радиосигналов, обеспечивающих стабильную работу систем управления и передачи данных. Однако радиосигналы, передаваемые с БПЛА, подвержены различным искажениям, таким, как шумы, помехи и потери при распространении, что затрудняет их точное восстановление на приемной стороне.

В традиционной радиотехнике для восстановления и очистки сигналов применяются классические методы обработки, включая преобразование Фурье, вейвлет-преобразование и фильтрацию. Несмотря на их эффективность в определенных сценариях, данные методы имеют ограничения при работе с сильно зашумленными и нелинейно искаженными сигналами. В связи с этим возникает потребность в разработке более адаптивных и мощных подходов, способных восстанавливать радиосигналы с высокой точностью.

Одним из перспективных направлений является применение методов глубокого обучения, в частности вариационных автоэнкодеров (VAE), которые способны обучаться на данных и находить оптимальные способы восстановления сигналов. Нейросетевые методы превосходят классические алгоритмы за счет способности анализировать сложные нелинейные зависимости, выявлять скрытые закономерности в данных и адаптироваться к разнообразным искажениям. Вариационные автоэнкодеры, в отличие от обычных автоэнкодеров, обладают вероятностной природой и позволяют моделировать неопределенность сигнала, что особенно важно при наличии шумов. Они обеспечивают более устойчивую и точную реконструкцию, так как их латентное пространство организуется таким образом, чтобы эффективно представлять значимые особенности входных данных.

Использование VAE позволяет не только восстанавливать исходный сигнал с высокой точностью, но и улучшать его устойчивость к шумам и потерям информации.

В статье исследуется возможность применения нейросетевых методов для восстановления радиосигналов с БПЛА. В рамках работы построена модель вариационного автоэнкодера (VAE), предназначенная для восстановления зашумленных сигналов, и проведено сравнение ее эффективности с традиционными методами, в частности с фильтром Калмана. Анализируется, насколько VAE способен улучшить точность реконструкции по сравнению с фильтром Калмана, учитывая различные уровни шума и искажений. Для этого проводятся эксперименты на открытом датасете радиосигналов, оценивается качество восстановления по метрикам, таким, как пиковое отношение сигнал-шум (PSNR), среднеквадратичная ошибка (MSE) и средняя абсолютная ошибка (MAE). В результате работы выявляются преимущества и ограничения предложенного подхода, а также определяются сценарии, в которых использование VAE оказывается более эффективным для восстановления радиосигналов в реальных условиях эксплуатации БПЛА.

1. Проблема классических методов восстановления радиосигнала. На практике сигналы чаще всего представлены в цифровом виде, то есть в виде последовательности отсчётов. Дискретное преобразование Фурье [1] предназначено для работы с такими оцифрованными сигналами. DFT позволяет выполнить переход от временного представления к частотному для дискретного сигнала $x[n]$ с N отсчётами. В итоге получаем $X[k]$ – индекс частного компонента, определяемого формулой:

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-\frac{2i\pi kn}{N}}. \quad (1)$$

DFT дает спектр сигнала в дискретной форме, позволяя анализировать цифровые сигналы и их частотное содержание [2]. Это преобразование используется во многих приложениях обработки сигналов, таких, как фильтрация, сжатие и анализ спектра. Однако из-за высокой вычислительной сложности прямое применение DFT для больших объёмов данных может быть ресурсоёмким [3].

Вейвлет-преобразование [4] – это метод анализа сигналов, который позволяет разложить сигнал на временные и частотные компоненты. В отличие от преобразования Фурье, которое представляет сигнал в виде суммы гармонических функций с фиксированными частотами, вейвлет-преобразование использует вейвлеты – ограниченные во времени функции, которые могут изменяться как по масштабу, так и по сдвигу [5]. Вейвлет-преобразование особенно полезно для анализа нестационарных сигналов, чьи частотные компоненты меняются во времени. Это делает его незаменимым для задач, где важны локальные изменения сигнала, например, при сжатии и восстановлении сигналов, обнаружении событий и анализе временных рядов.

В реальных приложениях, где сигналы обычно представлены в виде дискретных отсчетов [6], используется дискретное вейвлет-преобразование (DWT). Оно упрощает вычисления за счёт дискретизации масштабов и сдвигов. DWT для сигнала $x[n]$ можно выразить через сумму разложений с использованием дискретных масштабов $a = 2^j$ и сдвигов $b = k * 2^j$:

$$W_{j,k} = \sum_n x[n] \psi_{j,k}[n], \quad (2)$$

где $\psi_{j,k}[n] = \frac{1}{\sqrt{2^j}} \psi\left(\frac{n-k2^j}{2^j}\right)$.

Фильтр Калмана [7] используется для оптимальной оценки параметров сигнала в условиях шума. Основное уравнение обновления состояния записывается в виде:

$$x_{k|k} = x_{k|k-1} + K_k(z_k - Hx_{k|k-1}), \quad (3)$$

где K_k – матрица Калмана (матрица весовых коэффициентов); z_k – наблюдаемое значение на шаге k ; H – матрица наблюдений.

Фильтр Калмана помогает улучшить прогноз состояния, минимизируя влияние шума [8].

В условиях эксплуатации БПЛА классические методы восстановления радиосигналов сталкиваются с рядом ограничений. Согласно исследованию, опубликованному в журнале «Sensors» [9], традиционные методы, такие, как радарные и акустические системы, испытывают трудности при обнаружении и классификации БПЛА из-за их малых размеров и низкой отражающей способности. Кроме того, оптические системы подвержены влиянию погодных условий и могут путать дроны с другими объектами, например, птицами.

2. Смежные работы. В области обработки радиосигналов с БПЛА уже активно применяются методы глубокого обучения, особенно нейронные сети, для повышения точности и эффективности обработки сигналов. Рассмотрим некоторые из них.

В работе «Deep Learning Approach to UAV Detection and Classification by Using Compressively Sensed RF Signal» [10] авторы предложили метод обнаружения и классификации БПЛА, основанный на сжатии радиочастотных сигналов и использовании глубоких нейронных сетей. Сначала радиосигналы БПЛА сжимаются с помощью техники compressive sensing, что снижает объем данных и облегчает их обработку. Затем сжатые сигналы анализируются с использованием глубоких нейронных сетей для точного определения наличия БПЛА и их классификации по типам. Экспериментальные результаты показали, что предложенный метод обеспечивает высокую точность обнаружения и классификации БПЛА даже при наличии шумов и помех.

Первоначально нейронные сети применялись преимущественно для задач классификации радиосигналов [11]. Однако, с учетом успехов их использования в обработке аудиоданных [12], начали активно развиваться аналогичные методы в области анализа радиосигналов [13].

В статье «RF-Diffusion: Radio Signal Generation via Time-Frequency Diffusion Models» [14] рассматривается применение генеративных моделей, включая вариационные автоэнкодеры (VAE), для синтеза и дополнения радиочастотных (RF) данных. VAE обучаются распределению входных сигналов и генерируют новые образцы, что полезно для моделирования и прогнозирования радиосигналов. Однако классические VAE ограничены в обработке RF-сигналов, так как могут терять важные временные и фазовые характеристики. В качестве альтернативы авторы предлагают диффузионные модели, которые лучше учитывают сложную структуру сигналов. Тем не менее, условные VAE (CVAE) остаются конкурентоспособными в задачах дополнения и предсказания пропущенных фрагментов сигнала. В экспериментальной части RF-Diffusion сравнивается с VAE, CVAE и DCGAN, демонстрируя превосходство диффузионных моделей в синтезе Wi-Fi и FMCW сигналов. Однако CVAE показывают хорошие результаты в контролируемом генеративном моделировании, когда важно учитывать параметры канала или тип сигнала.

3. Вариационный автоэнкодер для решения задачи восстановления радиосигнала.

Вариационный автоэнкодер (VAE) – это тип нейронной сети, который комбинирует вероятностное моделирование и методы глубокого обучения для кодирования данных в латентное пространство и генерации новых данных [15]. VAE отличается от классического автоэнкодера тем, что он обучается моделировать вероятностное распределение в скрытом пространстве, а не отображать входные данные в фиксированные детерминированные представления. Основными компонентами вариационного автоэнкодера является вероятностная модель, вариационное приближение и функция потерь ELBO.

3.1. Вероятностная модель. В отличие от обычных автоэнкодеров, которые детерминировано кодируют входные данные в латентное пространство, вариационный

автоэнкодер (VAE) обучается восстанавливать вероятностное распределение входных данных. Он основывается на вероятностной модели:

$$p(x, z|\Theta) = p(z)p(x|z, \Theta), \quad (4)$$

где z – латентное представление данных; $p(z)$ – априорное распределение, обычно $N(0, 1)$; $p(x|z, \Theta)$ – распределение, моделирующее распределение данных x , заданных z .

Для бинарных данных используется модель на основе распределения Бернулли, где вероятность появления каждого пикселя (или другого бинарного признака) представляется в виде произведения независимых распределений:

$$p(x, z|\Theta) = \prod_{i=1}^D p_i(z, \Theta)^{x_i} (1 - p_i(z, \Theta))^{1-x_i}, \quad (5)$$

где D – размерность входных данных.

3.2. Вариационное приближение. Вычисление апостериорного распределения $p(x|z)$ напрямую является сложной задачей, поскольку требует интегрирования по всем возможным значениям z . Поэтому в VAE используется вариационное приближение $q(z|x, \phi)$, которое аппроксимирует истинное апостериорное распределение.

Обычно $q(z|x, \phi)$ задаётся нормальным распределением с параметрами, зависящими от входных данных:

$$q(z|x, \phi) = N(z|\mu(x, \phi), \text{diag}(\delta^2(x, \phi))), \quad (6)$$

где $\mu(x, \phi)$ – среднее распределения; $\delta^2(x, \phi)$ – дисперсия.

3.3. Функция потерь. Чтобы обучить VAE, используется нижняя вариационная граница (ELBO), которая включает два слагаемых:

- ошибка реконструкции (Reconstruction Loss), которая измеряет, насколько хорошо декодер восстанавливает данные: $E_{q(z|x, \phi)}[\log p(x|z, \Theta)]$;
- мера различия (KL-дивергенция) между апостериорным $q(z|x, \phi)$ и априорным $p(z)$ величинами: $D_{KL}(q(z|x, \phi)||p(z))$.

Итоговая функция потерь:

$$L(x, \phi, \Theta) = E_{q(z|x, \phi)}[\log p(x|z, \Theta)] - D_{KL}(q(z|x, \phi)||p(z)) \quad (7)$$

3.4. Реализация VAE. Распределение $q(z|x, \Theta)$ называется энкодером, так как оно кодирует входные данные x в латентное представление z . Распределение $p(x|z, \phi)$ называется декодером, поскольку оно декодирует латентное представление обратно в данные x .

Для параметризации этих распределений используются две нейронные сети:

- энкодер принимает на вход x и возвращает вектор размерности $2 \times d$, который задает среднее $\mu(x, \phi)$ и стандартное отклонение $\delta(x, \phi)$ для распределения $q(z|x, \Theta)$;
- декодер принимает на вход латентное представление z и возвращает логиты для распределения $p(x|z, \phi)$.

На рисунке 1 приведена структура VAE, которая, как видно, похожа на структуру обычного автоэнкодера, но с добавлением стохастической переменной ϵ .




Рис. 1. Структура VAE

4. Описание набора данных. Обучение модели происходило на открытом датасете DeepSig Dataset: RadioML 2018.01A, который широко используется в исследованиях по обработке радиосигналов. Данный набор данных содержит синтетически сгенерированные

радиосигналы с 24 типами модуляций, охватывающими как аналоговые, так и цифровые схемы модуляции. Данные были созданы с целью разработки и тестирования алгоритмов классификации, распознавания и анализа сигналов, что делает их подходящими для задач, связанных с реконструкцией и обработкой радиосигналов.

Файлы датасета хранятся в формате HDF5, который оптимизирован для работы с большими объемами данных и позволяет эффективно загружать и обрабатывать сигналы. В датасете содержится более 2,5 миллионов примеров, каждый из которых представлен 1024 комплексными отсчетами (I/Q компоненты). Это делает набор данных удобным для задач машинного обучения, связанных с анализом временных рядов и спектральных характеристик сигналов.

Каждый пример сопровождается метаинформацией, включающей:

- тип модуляции (например, BPSK, QPSK, AM, FM и др.);
- отношение сигнал/шум (SNR) в диапазоне от -20 до +30 дБ;
- дополнительные параметры, характеризующие условия генерации сигнала.

Изначально датасет создавался для решения задачи классификации радиосигналов в рамках хакатона по машинному обучению. Однако, учитывая, что он содержит разнообразные типы модуляций и различные уровни шума, его можно эффективно использовать и для решения других задач, включая реконструкцию сигналов, что является целью этого исследования.

В рамках подготовки данных для обучения модели были выполнены следующие шаги:

- фильтрация по типу модуляции: из 24-х представленных видов были отобраны наиболее распространенные модуляции, используемые при передаче сигналов с БПЛА, а именно: BPSK (Binary Phase Shift Keying), QPSK (Quadrature Phase Shift Keying), 8PSK (8-Phase Shift Keying), 16QAM (16-Level Quadrature Amplitude Modulation), 64QAM (64-Level Quadrature Amplitude Modulation). Можно было добавить больше типов модуляции, чтобы улучшить обобщающую способность модели, однако при больших размерах выборки происходило переполнение памяти модели;
- фильтрация по уровню SNR: сигналы с крайне низким SNR (ниже -10 дБ) были исключены, так как они содержат значительное количество шума и могут затруднить обучение модели;
- разделение данных на обучающую и тестовую выборки: после фильтрации в распоряжении осталось около 500 тысяч примеров, которые были разбиты следующим образом: 80% (400 тыс.) примеров – для обучения модели, 20% (100 тыс.) примеров – для тестирования.

5. Архитектура и обучение VAE. Архитектура вариационного автоэнкодера, созданного для решения поставленной задачи, приведена на рисунке 2. Представленная архитектура является сверточным вариационным автоэнкодером (VAE) с однонаправленными свертками (Conv1D), предназначенным для обработки одномерных сигналов размерностью 1024×2 . Модель включает три ключевых компонента: энкодер, блок репараметризации и декодер. Энкодер состоит из двух последовательных сверточных слоев с фильтрами размерности 64 и 128, функциями активации ReLU и операциями нормализации и субдискретизации (MaxPooling1D). После этого применяется слой выравнивания (Flatten), преобразующий выход в векторное представление, которое затем разделяется на два набора параметров латентного пространства: z_{mean} и $z_{\text{log_var}}$.




Рис. 2. Архитектура VAE

Для обеспечения стохастичности используется метод репараметризации: латентное представление z формируется как сумма z_{mean} и случайной величины, масштабированной на $z_{\text{log_var}}$, имеющей размерность 64. Декодер выполняет восстановление сигнала с помощью последовательности операций: увеличение размерности через UpSampling1D, свертка с

увеличением числа фильтров (128 и 64) и финальная свертка с двумя фильтрами. Выходной слой использует сигмоидную активацию для получения реконструированного сигнала.

Полученная архитектура вариационного автокодировщика представлена более сжато на рисунке 3.




Рис. 3. Общее представление архитектуры VAE

Было замечено, что при увеличении количества сверточных слоев, то есть при более глубокой архитектуре, модель сразу начинает переобучаться. Это значит, что вариационный автоэнкодер достаточно быстро выучивает все закономерности в данных и при дальнейшем усложнении архитектуры начинает подстраиваться под локальные шумы тренировочной выборки, а увеличение количества фильтров в сверточных слоях, наоборот, положительно сказалось на качестве модели. Это можно объяснить тем, что каждый фильтр в сверточном слое отвечает за выделение определенных признаков из входных данных. Увеличение количества фильтров позволяет модели извлекать больше разнообразных признаков, что делает ее более гибкой и способной лучше аппроксимировать сложные распределения данных.

В данной задаче именно нормализация входных данных помогла достичь хорошего качества. Также в лучшую сторону повлияло увеличение размерности латентного представления до 64. В ходе обучения не возникло переобучения, что говорит о хорошей обобщающей способности модели.

Обучение модели происходило на платформе Kaggle, где и располагается датасет DeepSig Dataset: RadioML 2018.01A. Модель обучалась 50 эпох на видеокарте GPU T4 x2, которую бесплатно предоставляет Kaggle.

Метриками качества были выбраны MSE (mean squared error), MAE (mean absolute error) и PSNR (peak signal-to-noise ratio). MSE входит в функцию потерь VAE и отвечает за измерение расхождения между восстановленным и исходным сигналами, поэтому его целесообразно использовать, как метрику для оценки качества модели. Использование MSE позволяет выделить крупные ошибки восстановления, потенциально влияющие на безопасность и успешность выполнения миссий.

MAE дает представление о средней точности восстановления и более устойчив к шумам, что важно при обработке больших объемов данных, например, телеметрии, ее проще интерпретировать как «средняя абсолютная ошибка». PSNR (пиковое отношение сигнал/шум) показывает, насколько сигнал не искажен шумами, чтобы передаваемые данные, например, команды управления БПЛА, были четкими и интерпретируемыми.

6. Анализ и сравнение результатов работы модели с фильтром Калмана. В таблице 1 представлены значения метрик, полученные на разных эпохах обучения на тренировочной и валидационной (тестовой) выборках. Стоит отметить, что уже на первой эпохе значения

метрик на обеих выборках достаточно хорошие и в случае MSE значительный спад наблюдается на первых 10 эпохах, а дальше изменение происходит достаточно медленно.

Таблица 1. Значения метрик модели на тренировочной и тестовой выборке

Номер эпохи обучения	MSE train	MAE train	PSNR train	MSE val	MAE val	PSNR val
1	0,0062	0,0639	22,0991	0,0058	0,0615	22,3997
5	0,0049	0,0545	23,1420	0,0048	0,0539	23,4103
10	0,0045	0,0520	23,4506	0,0045	0,0519	23,4519
15	0,0044	0,0512	23,5440	0,0044	0,0509	23,5814
20	0,0043	0,0506	23,6356	0,0043	0,0506	23,6398
25	0,0043	0,0500	23,6975	0,0043	0,0499	23,7081
30	0,0042	0,0497	23,7400	0,0042	0,0497	23,7457
35	0,0042	0,0496	23,7604	0,0042	0,0494	23,7770
40	0,0042	0,0493	23,7901	0,0042	0,0492	23,8151
45	0,0042	0,0492	23,8146	0,0042	0,0491	23,8195
50	0,0041	0,0491	23,8159	0,0041	0,0491	23,8200

График изменения ошибки (Loss) на каждой эпохе (Epochs) представлен на рисунке 4.




Рис. 4. График изменения ошибки модели на обучении и валидации

В таблице 1 по значениям метрик MAE и PSNR наглядно видна хорошая обобщающая способность модели. Значения метрик стабильно изменяются в лучшую сторону: в случае MAE это почти линейный спад, а PSNR стабильно растет. В конце обучения MSE и MAE на тренировочной и валидационной выборках стали равны, но это нижняя граница нормы, чтобы говорить о хорошей обобщающей способности модели. PSNR на валидационной выборке немного лучше, чем на тренировочной, что подтверждает качество построенной модели.

На рисунке 5 продемонстрирован рост метрики PSNR (Value) на каждой эпохе обучения (Epochs).




Рис. 5. График изменения PSNR на обучении и валидации

Если посмотреть на значения метрик, полученные на 50 эпохе в таблице 1, то MSE указывает на то, что в среднем квадрат ошибки (разности) между значениями оригинального и восстановленного сигналов равен 0,0041. Это небольшое значение, если считать, что сигнал нормализован в диапазоне $[0,1]$, то $MSE = 0,0041$ соответствует средней разнице $\pm 0,064$ между восстановленным и оригинальным сигналом. В случае $MAE = 0,0491$ это означает, что восстановленный сигнал отличается от оригинального в среднем на 4,91%, что является хорошим показателем для зашумленного сигнала. В контексте управления БПЛА это допустимый уровень ошибки, если сигнал остается читаемым и восстановление сохраняет ключевые параметры (амплитуду, фазу, модуляцию). В заключение, $PSNR = 23,82$ на валидации (на тренировочной выборке при округлении получим такое же значение) свидетельствует о минимальном присутствии шума в восстановленном сигнале. Также стоит отметить, что в зашумленных данных $PSNR=25$ считается почти идеальным восстановлением сигнала. Значения метрик качества нужно оценивать вместе и $MSE = 0,0041$, $MAE = 0.0491$ и $PSNR = 23.82$ согласуются друг с другом: отклонения небольшие, и сигнал в целом хорошо восстановлен.

Исходя из вышеизложенного можно сделать вывод, что обученная модель хорошо справляется со своей задачей, но для полного анализа нужно сравнить ее показатели с классическим методом восстановления.

Для примера был взят и реализован фильтр Калмана. Для обработки сигналов использовался одномерный фильтр Калмана, поскольку рассматриваемые радиосигналы представляют собой последовательности 1024 отсчетов (I/Q-компонент). Входные данные

перед фильтрацией были представлены в виде одномерных временных рядов, соответствующих амплитудным значениям.

Фильтрация осуществлялась по следующей схеме:

- инициализация параметров: начальное значение сигнала принимается равным первому измеренному отсчету, начальная оценка ошибки устанавливается на уровне 1.0. Определяются параметры фильтра: ковариация процесса (process variance) – $1e-5$, ковариация измерений (measurement variance) – 0.1;
- прогнозирование следующего состояния: оценка сигнала на текущем шаге принимается за предсказание следующего значения, ошибка прогноза обновляется с учетом ковариации процесса;
- обновление оценки: рассчитывается калмановский коэффициент, который определяет, насколько следует доверять новым измерениям по сравнению с предыдущими оценками; итоговая оценка сигнала корректируется на основе разницы между реальным измерением и прогнозируемым значением, ошибка обновляется с учетом влияния нового измерения;
- алгоритм применяется последовательно ко всем 1024 отсчетам каждого примера из датасета.

В итоге $MSE = 0,4904$ является достаточно большой ошибкой даже для изначально зашумленного сигнала, как и $MAE = 0,5582$. $PSNR = 10,7813$ говорит о том, что уровень шума соизмерим с самим сигналом и отличить сигнал от шума достаточно трудно.

В итоге можно сделать вывод, что с данной задачей восстановления сигнала хорошо справляется построенная архитектура VAE, что выражается и в значениях метрик качества и в том, что классический фильтр Калмана не справился с восстановлением зашумленных сигналов.

Заключение. В данной статье были рассмотрены классические методы восстановления радиосигнала и выявлено, что они не всегда могут являться оптимальным способом решения поставленной задачи в силу многих ограничений. Реализован вариационный автоэнкодер для восстановления зашумленного радиосигнала на датасете DeepSig Dataset: RadioML 2018.01A: архитектура классического VAE, состоящая из двух сверточных слоев и субдискретизации (MaxPooling1D), с применением нормализации к входным данным, что помогло улучшить качество модели.

В результате обучения алгоритма, описанного выше, были получены графики изменения ошибки и роста метрик на тренировочной и валидационной (тестовой) выборках. Также составлена таблица значений метрик качества (MSE, MAE, PSNR) на разных эпохах обучения для контроля обобщающей способности модели. Проведен анализ полученных метрик и их сравнение с метриками, полученными в результате применения фильтра Калмана к данному датасету. Доказано, что для решения данной задачи эффективнее использовать нейронные сети (в частности, построенную архитектуру), чем классические методы восстановления радиосигнала.

Для восстановления радиосигнала с БПЛА применение нейронных сетей, таких, как VAE, зачастую оказывается более эффективным, чем использование классических методов. Это связано с тем, что нейронные сети способны обучаться сложным зависимостям и адаптироваться к различным типам шумов и искажений, характерным для реальных условий передачи сигналов. В отличие от классических подходов, которые опираются на аналитические модели и требуют точного знания параметров сигнала, нейронные сети могут восстанавливать сигналы, опираясь на данные и минимизируя метрики потерь, такие, как ошибка восстановления или уровень битовых ошибок (BER). Благодаря этому нейронные сети

обеспечивают более высокое качество реконструкции радиосигнала в условиях высокой зашумленности или нестабильного канала связи, что особенно важно для задач, связанных с БПЛА.

Необходимо отметить, что выбор метода восстановления радиосигнала может зависеть от типа конкретной задачи или самих данных, поэтому не исключено, что иногда классические методы восстановления радиосигнала могут оказаться эффективнее нейронных сетей.

Список источников

1. Кухарчук Н.В. Редактирование звукового спектра с использованием дискретного преобразования Фурье / Н.В. Кухарчук // Конференция «Информационные технологии и автоматизация управления» (Омск, 26–27 мая 2023 г.): тез. докл. – Омск, 2023. – С. 132-135.
2. Пахомов А.А. Преобразование Фурье и вейвлеты в предобработке данных / А.А. Пахомов, И.А. Седых // Летняя школа молодых ученых: сб. науч. тр. – Липецк, 2024. – С. 67-68.
3. Кошелева Д.Д. Преобразование Фурье и быстрое преобразование Фурье / Д.Д. Кошелева, А.В. Дронина // Инновации. Наука. Образование, 2021. – №38. – С. 626-632.
4. Манонина И.В. Применение вейвлет-анализа для обработки сигналов систем передачи информации / И.В. Манонина, В.В. Шестаков // Научные технологии в космических исследованиях Земли, 2024. – Т.16 – №5. – DOI:10.36724/2409-5419-2024-16-3-30-38.
5. Калмыков И.А. Ортогональная обработка сигналов с использованием математических моделей целочисленных вейвлет-преобразований, реализованных в модулярных кодах классов вычетов / И.А. Калмыков, Н.К. Чистоусов, Н.И. Калмыкова и др. // Инженерный вестник Дона, 2023. – №3. – С. 182-202.
6. Андреев Д.А. Обработка цифровой информации на основе вейвлет-преобразования / Д.А. Андреев, В.А. Лондинов, О.Ю. Тимошевская // Конференция «Инновационные, информационные и коммуникационные технологии» (Сочи, 01-10 октября 2021 г.): тез. докл. – Сочи, 2021. – С. 66-70.
7. Козырев Г.И. Восстановление входных сигналов динамических измерительных систем с помощью цифровой обратной фильтрации / Г.И. Козырев, Е.О. Юдицких // Измерительная техника, 2023. – №5. – DOI:10.32446/0368-1025it.2023-5-10-16.
8. Комарова К.В. Анализ восстановления квадратурных сигналов по двум пилот-сигналам / К.В. Комарова // Конференция «XLIX Огаревские чтения» (Саранск, 07-13 декабря 2020 г.): тез. докл. – Саранск, 2020. – С. 227-281.
9. Yang Sh., Luo Y., Miao W., et al. RF signal-based UAV detection and mode classification. Sensors, 2021, v.23, no. 12, pp. 21, DOI:10.3390/e23121678.
10. Mo Y., Huang J., Qian G. Deep learning approach to UAV detection and classification by using compressively sensed RF signal. Sensors, 2022, no. 8: 3072, DOI:10.3390/s22083072.
11. Ушакова А.М. Классификация модулированных радиосигналов с использованием нейронных сетей / А.М. Ушакова // Конференция «Цифровая обработка сигналов и ее применение DSPA» (Москва, 29-31 марта 2023 г.): тез. докл. – Москва, 2023. – С. 358-362.
12. Саввин С.В. Алгоритмические способы построения сверхразрешения видеоданных в условиях аппликативных помех с использованием глубоких нейронных сетей / С.В. Саввин // Вестн. Воронежского гос. ун-та, Сер. Системный анализ и информационные технологии, 2021. – № 4. – С. 107-120.
13. Евстратько В.В. Цифровой радиоприемник на основе нейронной сети / В.В. Евстратько, А.И. Коноваленко, А.В. Мишунов, и др. // Журнал радиоэлектроники, 2024. – №1. – DOI:10.30898/1684-1719.2024.1.5.
14. Chi G., Yang Z., Wu Ch. et al. RF-diffusion: Radio signal generation via time-frequency diffusion. ACM MobiCom '24: Proceedings of the 30th annual international conference on mobile computing and networking, 2024, pp. 77-92, DOI:10.1145/3636534.3649348.
15. Гергет О.М. Разработка моделей искусственных нейронных сетей для вариационного автоэнкодера / О.М. Гергет, В.В. Лаптев // Конференция «Молодежь и современные информационные технологии» (Томск, 22-26 марта 2021 г.): тез. докл. – Томск, 2021. – С. 51-52.

Фелагерева Евгения Юрьевна. Бакалавр в области радиофизики. Основные направления исследования автора: машинное обучение, нейронные сети, радиофизика. ORCID: 0009-0001-2406-1225, efelagereva@gmail.com. 350040, г. Краснодар, ул. Ставропольская, 149.

Рудоман Нэлли Радиковна. Старший преподаватель кафедры оптоэлектроники ФГБОУ ВО «Кубанский государственный университет». Основные направления исследования автора: физика твердого тела, компьютерное моделирование физических явлений, машинное обучение, искусственный интеллект, квантовые компьютеры, квантовая криптография. AuthorID: 39466, SPIN: 5844-2932, ORCID: 0009-0003-4308-235X. rudnel@ftf.kubsu.ru. 350040, г. Краснодар, ул. Ставропольская, 149.

Кузякина Марина Викторовна. Канд. физ.-мат. наук, доцент кафедры геоинформатики ФГБОУ ВО «Кубанский государственный университет». Основные направления исследований автора: анализ данных, машинное обучение, искусственный интеллект, геоинформатика, физика атмосферы, геостатистика. AuthorID: 522457, SPIN: 4945-6665, ORCID: 0000-0003-0492-3630, MarinaVkuzyakina@gmail.com. 350040, г. Краснодар, ул. Ставропольская, 149.

UDC 004.032.26

DOI:10.25729/ESI.2025.39.3.003

Development of neural network architecture for radio signal recovery from UAVs

Eugenia Yu. Felagereva¹, Nelly R. Rudoman¹, Marina V. Kuzyakina^{1,2}

¹Kuban state university,

Russia, Krasnodar, efelagereva@gmail.com

²Kuban state university of technology

Russia, Krasnodar

Abstract. This study examines the problem of applying classical radio signal recovery methods. The use of neural networks, namely autoencoders, is proposed as a solution. The architecture of a variational autoencoder has been developed to solve the problem of radio signal recovery from an unmanned aerial vehicle. To train and test the model, a large dataset containing radio signals of various types of modulations and noise levels was used, DeepSig Dataset: RadioML 2018.01A. The aim of the study is to develop an architecture that shows the best metrics for radio signal recovery than classical methods. The quality metrics used are PSNR, MSE, and MAE, and the Adam optimizer. The Kalman filter was also applied to the dataset, which showed two orders of magnitude worse results in all quality metrics. The data obtained show that classical algorithms for restoring distorted radio signals may not always show decent quality of work.

Keywords: variational autoencoder, radio signal, UAV, Kalman filter

References

1. Kukharchuk N.V. Redaktirovanie zvukovogo spektra s ispol'zovaniem diskretnogo preobrazovaniya Fur'e [Editing of the sound spectrum using the discrete Fourier transform]. Konferentsiya "Informatsionnye tekhnologii i avtomatizatsiya upravleniya" (Omsk, 26–27 maya 2023 g.) [Conference "Information Technologies and Automation of Control" (Omsk, May 26–27, 2023)], 2023, pp. 132-135.
2. Pakhomov A.A., Sedykh I.A. Preobrazovanie Fur'e i veivlety v predobrabotke dannykh [Fourier transform and wavelets in data preprocessing]. Letnyaya shkola molodykh uchenykh [Summer School of Young Scientists], 2024, pp. 67-68.
3. Kosheleva D.D., Dronina A.V. Preobrazovanie Fur'e i bystroe preobrazovanie Fur'e [Fourier transform and fast Fourier transform]. Innovatsii. Nauka. Obrazovanie [Innovations. Science. Education], 2021, no. 38, pp. 626-632.
4. Manonina I.V., Shestakov V.V. Primenenie veivlet-analiza dlya obrabotki signalov sistem peredachi informatsii [Application of wavelet analysis for processing signals in information transmission systems]. Naukoemkie tekhnologii v kosmicheskikh issledovaniyakh Zemli [High-Tech technologies in space Earth studies], 2024, vol. 16, no. 5, DOI:10.36724/2409-5419-2024-16-3-30-38.
5. Kalmykov I.A., Chistousov N.K., Kalmykova N.I. et al. Ortogonal'naya obrabotka signalov s ispol'zovaniem matematicheskikh modeley tselochislennykh veyvlet-preobrazovaniy, realizovannykh v modulyarnykh kodakh klassov vychetov [Orthogonal signal processing using mathematical models of integer wavelet transforms implemented in modular residue class codes]. Inzhenernyy vestnik Dona [Engineering Bulletin of the Don], 2023, no. 3, pp. 182-202.
6. Andreev D.A., Londikov V.A., Timoshevskaya O.Yu. Obrabotka tsifrovoi informatsii na osnove veivlet-preobrazovaniya [Processing of digital information based on wavelet transform]. Konferentsiya "Innovatsionnye, informatsionnye i kommunikatsionnye tekhnologii" (Sochi, 01–10 oktyabrya 2021 g.) [Conference "Innovative, Information and Communication Technologies" (Sochi, October 1–10, 2021)], 2021, pp. 66-70.

7. Kozyrev G.I., Yuditiskikh E.O. Vosstanovlenie vkhodnykh signalov dinamicheskikh izmeritel'nykh sistem s pomoshch'yu tsifrovoy obratnoi fil'tratsii [Restoration of input signals of dynamic measurement systems using digital inverse filtering]. *Izmeritel'naya tekhnika* [Measurement techniques], 2023, no. 5, DOI: 10.32446/0368-1025it.2023-5-10-16.
8. Komarova K.V. Analiz vosstanovleniya kvadraturnykh signalov po dvum pilot-signalam [Analysis of quadrature signal reconstruction based on two pilot signals]. *Konferentsiya "XLIX Ogarevskie chteniya"* (Saransk, 07–13 dekabrya 2020 g.) [Conference "XLIX Ogarev Readings" (Saransk, December 7–13, 2020)], 2020, pp. 227–281.
9. Yang Sh., Luo Y., Miao W., et al. RF signal-based UAV detection and mode classification. *Sensors*, 2021, v.23, no. 12, pp. 21, DOI:10.3390/e23121678.
10. Mo Y., Huang J., Qian G. Deep learning approach to UAV detection and classification by using compressively sensed RF signal. *Sensors*, 2022, no. 8: 3072, DOI:10.3390/s22083072.
11. Ushakova A.M. Klassifikatsiya modulirovannykh radiosignalov s ispol'zovaniem neironnykh setei [Classification of modulated radio signals using neural networks]. *Konferentsiya «Tsifrovaya obrabotka signalov i ee primeneniye DSPA»* (Moskva, 29–31 marta 2023 g.) [Conference "Digital Signal Processing and its Applications DSPA" (Moscow, March 29–31, 2023)], 2023, pp. 358–362.
12. Savvin S.V. Algoritmicheskie sposoby postroeniya sverkhrazresheniya videodannykh v usloviyakh aplikativnykh pomekh s ispol'zovaniem glubokikh neironnykh setei [Algorithmic methods for constructing video data super-resolution under applicative interference using deep neural networks]. *Vestnik Voronezhskogo gosudarstvennogo universiteta, Seriya: Sistemnyi analiz i informatsionnye tekhnologii* [Bulletin of Voronezh State University, Series: System Analysis and Information Technologies], 2021, no. 4, pp. 107–120.
13. Evstrat'ko V.V. Tsifrovoy radiopriemnik na osnove neyronnoy seti [Digital radio receiver based on a neural network]. *Zhurnal radioelektroniki* [Journal of Radio Electronics], 2024, no. 1, DOI:10.30898/1684-1719.2024.1.5.
14. Chi G. et al. RF-diffusion: Radio signal generation via time-frequency diffusion, *Proceedings of the 30th Annual International Conference on Mobile Computing and Networking*, 2024, pp. 77–92.
15. Gerget O.M., Laptev V.V. Razrabotka modeley iskusstvennykh neyronnykh setey dlya variatsionnogo avtoenkodera [Development of artificial neural network models for a variational autoencoder]. *Konferentsiya "Molodezh' i sovremennyye informatsionnye tekhnologii"* (Tomsk, 22–26 marta 2021 g.) [Conference "Youth and Modern Information Technologies" (Tomsk, March 22–26, 2021)], 2021, pp. 51–52.

Felagereva Evgeniya Yurievna. Bachelor's degree in Radiophysics. The author's main research areas are machine learning, neural networks, and radiophysics. ORCID: 0009-0001-2406-1225, efelagereva@gmail.com. 350040, Krasnodar, st. Stavropol, 149.

Rudoman Nelly Radikovna. Senior Lecturer at the Department of Optoelectronics, Kuban State University. The author's main research areas are solid state physics, computer modeling of physical phenomena, machine learning, artificial intelligence, quantum computers, and quantum cryptography. AuthorID: 39466, SPIN: 5844-2932, ORCID: 0009-0003-4308-235X, rudnel@ftf.kubsu.ru. 350040, Krasnodar, st. Stavropol, 149.

Kuzyakina Marina Viktorovna. Candidate of Physical and Mathematical Sciences, Associate Professor of the Department of Geoinformatics, Kuban State University. The author's main research areas are data analysis, machine learning, artificial intelligence, geoinformatics, atmospheric physics, and geostatistics. AuthorID: 522457, SPIN: 4945-6665, ORCID: 0000-0003-0492-3630, MarinaVkuzyakina@gmail.com. 350040, Krasnodar, st. Stavropol, 149.

Статья поступила в редакцию 01.04.2025; одобрена после рецензирования 27.05.2025; принята к публикации 02.08.2025.

The article was submitted 04/01/2025; approved after reviewing 05/27/2025; accepted for publication 08/02/2025.