

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ/SYSTEM ANALYSIS,
MANAGEMENT AND PROCESSING OF INFORMATION

DOI: <https://doi.org/10.60797/IRJ.2025.160.34>

ИСПОЛЬЗОВАНИЕ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ УДАЛЕНИЯ ШУМА И
ВОССТАНОВЛЕНИЯ ИЗОБРАЖЕНИЙ В МЕДИЦИНСКОЙ И ТЕЛЕМЕТРИЧЕСКОЙ ПРАКТИКЕ

Научная статья

Набатов Н.Н.^{1,*}, Ерачина С.М.²

¹ORCID : 0009-0007-6657-1630;

²ORCID : 0009-0003-3989-1189;

¹ Байконурский филиал Московского авиационного института (национального исследовательского университета),
Байконур, Казахстан

²Московский авиационный институт (национальный исследовательский университет), Москва, Российская Федерация

* Корреспондирующий автор (mai[at]nabatovnn.ru)

Аннотация

В статье рассматривается задача удаления шума и восстановления изображений в медицинской и телеметрической практике. Целью исследования является разработка метода фильтрации зашумленных данных на основе сверточного автоэнкодера, позволяющего повысить качество визуальной информации. В работе проведён сравнительный анализ традиционных методов обработки изображений и современных нейросетевых подходов. В экспериментальной части использованы наборы микроскопических изображений и данные бортовой системы видеоконтроля (БСВК) ракеты-носителя. Предложенная архитектура автоэнкодера продемонстрировала преимущество по метрикам PSNR и SSIM по сравнению с классическими алгоритмами фильтрации. Научная новизна работы заключается в том, что впервые сверточный автоэнкодер применён одновременно к задаче фильтрации медицинских изображений и данных БСВК в единой постановке. Практическая значимость исследования состоит в возможности использования предложенного подхода для повышения достоверности телеметрической информации и качества диагностических изображений.

Ключевые слова: обработка изображений, удаление шума, автоэнкодер, глубокое обучение, телеметрия, медицинская визуализация, PSNR, SSIM.

THE USE OF CONVOLUTIONAL NEURAL NETWORKS FOR NOISE REMOVAL AND IMAGE RESTORATION
IN MEDICAL AND TELEMETRICAL PRACTICE

Research article

Nabatov N.N.^{1,*}, Yerachina S.M.²

¹ORCID : 0009-0007-6657-1630;

²ORCID : 0009-0003-3989-1189;

¹ Baikonur Branch of the Moscow Aviation Institute (National Research University), Baykonur, Kazakhstan

² Moscow Aviation Institute (National Research University), Moscow, Russian Federation

* Corresponding author (mai[at]nabatovnn.ru)

Abstract

The article examines the problem of noise removal and image restoration in medical and telemetrical practice. The aim of the study is to develop a method for filtering noisy data based on a convolutional autoencoder, which allows improving the quality of visual information. The work provides a comparative analysis of traditional image processing methods and modern neural network approaches. The experimental part uses sets of microscopic images and data from the Onboard Video Control System (OVCS) of a launch rocket. The proposed autoencoder architecture demonstrated an advantage in PSNR and SSIM metrics compared to classical filtering algorithms. The scientific novelty of the paper lies in the fact that, for the first time, a convolutional autoencoder has been applied simultaneously to the task of filtering medical images and OACS data in a single setting. The practical significance of the research consists in the possibility of using the suggested approach to improve the reliability of telemetrical information and the quality of diagnostic images.

Keywords: image processing, noise removal, autoencoder, deep learning, telemetry, medical imaging, PSNR, SSIM.

Введение

В последние десятилетия наблюдается устойчивый рост интереса к методам цифровой обработки изображений, обусловленный широким спектром их применения: от медицинской диагностики до промышленного контроля качества и обработки телеметрических данных с космических аппаратов. Качество изображений напрямую влияет на точность последующего анализа и принятие решений, что делает задачу восстановления изображений, в частности устранения шума, актуальной и практически значимой.

Шум в изображениях представляет собой нежелательное искажение визуальной информации, возникающее как в процессе формирования изображения (например, вследствие ограничений чувствительности сенсоров, квантовых флуктуаций и оптических аберраций), так и на этапах его передачи, хранения и реконструкции. В зависимости от физических и технических факторов, шум может носить гауссовский, импульсный, мультипликативный или комбинированный характер. Присутствие шума затрудняет интерпретацию изображений как специалистами, так и

автоматизированными системами анализа, особенно в случаях, требующих высокой пространственной точности и сохранения тонких структурных элементов.

Существующие классические методы подавления шума, включая линейные и нелинейные фильтры (фильтр Гаусса, медианный фильтр, фильтр Винера и др.), обеспечивают определённый уровень устранения шумов, однако зачастую сопровождаются утратой пространственной детализации, нарушением структурной целостности изображения и введением артефактов [6]. Указанные ограничения особенно критичны при работе с медицинскими и телеметрическими изображениями, где важна не только высокая степень шумоподавления, но и сохранение анатомических или технически значимых особенностей изображения.

В контексте указанных ограничений перспективным направлением представляется использование методов глубинного обучения, в частности — сверточных нейронных сетей (CNN), демонстрирующих высокую способность к аппроксимации сложных нелинейных зависимостей и автоматическому извлечению признаков. Обучение нейросетевых моделей на парах зашумленных и эталонных изображений позволяет формировать устойчивые аппроксиматоры, способные восстанавливать оригинальное изображение даже при наличии выраженных искажений [10]. Среди эффективных архитектур, применяемых для решения задач восстановления изображений, особое внимание уделяется автоэнкодерам, U-Net и их модификациям, отличающимся высокой точностью реконструкции, модульностью и возможностью масштабирования.

Применение нейросетевых подходов к задаче шумоподавления обладает рядом преимуществ: во-первых, такие модели адаптируются к статистике конкретных типов шума и особенностям визуального содержания; во-вторых, они демонстрируют способность к обобщению на новые типы данных при наличии ограниченного обучающего множества; в-третьих, обеспечивают высокое качество восстановления, превосходящее традиционные алгоритмы по объективным метрикам качества, таким как PSNR (Peak Signal-to-Noise Ratio), SSIM (Structural Similarity Index Measure) и MSE (Mean Squared Error).

Важным аспектом, требующим отдельного рассмотрения, является интерпретируемость нейросетевых решений, особенно в медицинских и аэрокосмических приложениях, где непредсказуемое поведение модели может привести к искаженным выводам. В связи с этим особую актуальность приобретает исследование устойчивости нейросетевых моделей к изменениям характеристик входных данных, а также разработка архитектур, обеспечивающих прозрачность и воспроизводимость результатов.

Настоящее исследование направлено на обоснование эффективности использования нейронных сетей для задач подавления шумов и восстановления изображений в прикладных контекстах медицины и телеметрии. В работе производится анализ архитектурных особенностей различных типов нейросетей (включая автоэнкодеры и U-Net), осуществляется обучение моделей на синтетических и реалистичных датасетах, имитирующих различные типы шумов и искажений, и проводится их сравнение с классическими алгоритмами фильтрации [4]. Эффективность рассматриваемых решений оценивается с использованием стандартных метрик качества восстановления и анализируется с позиций их применимости в условиях реальных задач — например, в автоматизированной обработке микроскопических медицинских изображений или телеметрических снимков с борта космических аппаратов.

Таким образом, использование сверточных нейронных сетей в задачах шумоподавления представляет собой научно обоснованный и технически эффективный подход, позволяющий обеспечить высокую точность восстановления изображений при сохранении их информативной структуры. Результаты настоящей работы вносят вклад в развитие интеллектуальных систем визуального анализа и могут быть использованы при проектировании прикладных решений в области медицинской диагностики, аэрокосмического мониторинга и смежных дисциплин.

Традиционные и нейросетевые методы удаления шума

Удаление шума (денойзинг) является одной из важнейших задач цифровой обработки изображений, особенно в тех случаях, когда от качества изображения зависит корректность последующего анализа. Шум может существенно снижать информативность изображения, затруднять распознавание объектов, ухудшать визуальное восприятие и мешать автоматизированной обработке. Это особенно критично в таких областях, как медицинская диагностика, биомедицинская визуализация, дистанционное зондирование Земли, а также в телеметрических и научных изображениях, полученных в условиях высокой чувствительности и низкой освещённости.

Характер шума может варьироваться в зависимости от источника его возникновения. Наиболее распространёнными являются следующие типы:

- Гауссовский шум, моделирующий случайные отклонения яркости, возникающие из-за тепловых и электронных колебаний.
- Импульсный шум («соль и перец»), возникающий при передаче данных или неисправности сенсора.
- Шум Пуассона, характерный для изображений при низкой освещённости и в медицинской визуализации.
- Мультипликативный шум, часто встречающийся в радиолокационных и ультразвуковых изображениях.

Существующие методы удаления шума можно разделить на две большие категории: традиционные (алгоритмические) и обучаемые (нейросетевые) [1].

2.1. Традиционные методы

Традиционные методы фильтрации изображений основываются на априорных предположениях о природе шума и структуре изображения. Они, как правило, не требуют предварительного обучения и применяются напрямую к входным данным. Ниже рассмотрены основные фильтры, применяемые для подавления различных типов шума.

2.1.1. Гауссов фильтр

Гауссов фильтр представляет собой линейную свёртку изображения с ядром, основанном на двумерной функции Гаусса:

$$G(x, y) = (1/2\pi q^2) \exp(-((x^2 + y^2)/(2q^2))) \quad (1)$$

где $G(x,y)$ — ядро фильтра в точке (x,y) ;

q — дисперсия (параметр «размытия»), определяющая степень сглаживания;

x,y — координаты пикселей относительно центра окна фильтра.

Фильтр эффективно подавляет аддитивный гауссовский шум и мелкие флуктуации яркости за счёт усреднения значений пикселей с учётом их пространственной близости.

Преимущества:

- простота реализации и высокая скорость выполнения;
- хорошо подавляет равномерный шум при относительно слабом размытии.

Недостатки:

- размывает границы и тонкие структуры;
- неэффективен при наличии импульсного шума.

2.1.2. Медианный фильтр

Вместо среднего значения пикселя в окрестности используется медиана, то есть центральное значение отсортированного по яркости списка соседей.

Эффективен для устранения импульсного шума, при котором отдельные пиксели резко отличаются по яркости от окружения.

Преимущества:

- сохраняет резкие границы объектов;
- не приводит к смещению значений, как это происходит при усреднении.

Недостатки:

- меньшая эффективность при гауссовском или комплексном шуме;
- при увеличении окна может исказить структуру изображения.

2.1.3. Фильтр Винера (Wiener filter)

Является адаптивным фильтром, основанным на оценке локальной дисперсии и среднего значения. Предполагается, что сигнал и шум можно статистически различить. Осуществляется частотная фильтрация с подавлением частот, на которых преобладает шум.

Формула фильтра Винера в частотной области:

$$H(u, v) = (S(u, v)) / (S(u, v) + N(u, v)) \quad (2)$$

где $H(u,v)$ — частотная характеристика фильтра Винера;

$S(u,v)$ — спектральная плотность мощности исходного (чистого) изображения;

$N(u,v)$ — спектральная плотность мощности шума;

u,v — координаты в частотной области (Фурье-пространство).

Предназначен для уменьшения шума при сохранении резкости. Особенно эффективен при известной спектральной плотности шума.

Преимущества:

- адаптивность к локальным условиям изображения;
- улучшение как шума, так и размытости (дефокусировки).

Недостатки:

- требует предварительной оценки шума и сигнала;
- может усиливать артефакты при неправильных параметрах.

2.1.4. Билатеральный фильтр (Bilateral filter)

Фильтр сочетает два весовых коэффициента: пространственный и радиометрический (по яркости):

$$I'(x) = 1/W(c) \sum_{i \in b} I(i) \exp(-(|x - i|^2)/2q_s^2) - (-(|I(x) - I(i)|^2)/2q_r^2)) \quad (3)$$

, где $I(x)$ — интенсивность пикселя в точке x ;

$I'(x)$ — новая (отфильтрованная) интенсивность;

W — коэффициент нормализации (сумма весов);

b — окрестность пикселя;

q_s и q_r — управляют пространственным и яркостным сглаживанием соответственно по расстоянию между пикселями и по разнице яркостей.

Сохраняет контуры и границы при сглаживании текстур. Подходит для изображений с переменным уровнем шума.

Преимущества:

- эффективен для устранения мелких флуктуаций при сохранении краёв;
- адаптивен к содержанию изображения.

Недостатки:

- вычислительно затратен;
- неустойчив к сильному шуму.

2.1.5. Нелокальные методы: Non-Local Means (NLM)

NLM-фильтр заменяет значение пикселя усреднённым значением других пикселей, находящихся в изображении, вес которых зависит от схожести их окрестностей, а не только от пространственной близости:

$$I'(x) = \sum_{i \in b} w(x, y) I(y) \quad (4)$$

где $I(x)$ — интенсивность пикселя в точке x ;

$I^{\wedge}(x)$ — новая (взвешенная) интенсивность;

$w(x,y)$ — вес, зависящий от сходства окрестностей вокруг пикселей xxx и uyu (чем похожее окружение, тем выше вес);

b — множество пикселей всего изображения или выбранного окна.

Предназначен для высокоточного шумоподавления без потери деталей. Особенно эффективен на текстурированных и повторяющихся структурах.

Преимущества:

- отлично сохраняет структуру и детали;
- работает на основе глобального контекста изображения.

Недостатки:

- очень высокая вычислительная сложность;
- медленная работа на больших изображениях без оптимизации.

Таким образом, в таблице 1 представлено обобщение по фильтрам, которые применяются для различных типов шумов.

Таблица 1 - Обобщение по традиционным фильтрам

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.1>

№ п/п	Метод	Эффективен против шума	Сохраняет детали	Вычисления	Примечание
1	Гауссов фильтр	Гауссовский	Частично	Быстрый	Универсальное сглаживание
2	Медианный фильтр	Импульсный	Хорошо	Быстрый	Предобработка, диагностика
3	Фильтр Винера	Гаусс, размытость	Средне	Средний	Частотная фильтрация, восстановление фокуса
4	Билатеральный фильтр	Гаусс, слабый шум	Хорошо	Средний	Медицинские изображения, HDR
5	Нелокальные методы	Разнотипный	Очень хорошо	Дорогой	Критичные задачи (медицина, наука)

Хотя классические методы остаются актуальными благодаря своей интерпретируемости и простоте, они часто демонстрируют ограниченные возможности при работе с реальными изображениями, где шум имеет сложную и неоднородную структуру. Кроме того, их параметры обычно подбираются вручную и не адаптируются к особенностям конкретного изображения.

2.2. Обучаемые (нейросетевые) методы

Современные достижения в области машинного обучения и компьютерного зрения способствовали широкому распространению нейросетевых подходов к обработке изображений. В частности, нейросетевые методы продемонстрировали высокую эффективность в задаче подавления шума, особенно в случаях, когда традиционные фильтры теряют точность или создают нежелательные искажения. Благодаря способности обучаться на больших выборках данных, такие модели могут учитывать сложные нелинейные зависимости и адаптироваться к различным видам шумов, сохраняя при этом важные детали изображения.

2.2.1. Сверточные нейронные сети (CNN) для удаления шума

Сверточные нейронные сети (Convolutional Neural Networks, CNN) являются основным инструментом для анализа изображений в нейросетевых архитектурах [12]. Их ключевая особенность — способность автоматически извлекать пространственные признаки с помощью обучаемых сверточных фильтров. В задаче денойзинга CNN обучаются преобразовывать зашумлённое изображение в его «чистую» версию.

Примеры архитектур:

- DnCNN (Denoising Convolutional Neural Network) — одна из первых глубоко сверточных моделей для подавления шума (использует несколько сверточных слоёв с batch normalization и ReLU, а обучается предсказывать не само изображение, а остаток шума, который затем вычитается);

- FFDNet — улучшенная архитектура, принимающая уровень шума как входной параметр, что позволяет фильтровать изображения с переменным уровнем зашумлённости;

- RED-Net (Residual Encoder-Decoder Network) — использует симметричную структуру автоэнкодера с прямыми остаточными связями между слоями кодировщика и декодировщика.

2.2.2. Автоэнкодеры

Автоэнкодеры — это тип нейронной сети, обучающийся восстанавливать входные данные через узкое «бутылочное горлышко» (сжатое представление). В задаче удаления шума используется денойзинг-автоэнкодер

(Denoising Autoencoder), который принимает зашумлённое изображение на вход и обучается восстанавливать исходное (чистое) изображение на выходе.

Особенности:

- простота архитектуры;
- хорошо работают с ограниченным числом типов шума.

Но в силу своих особенностей также ограничены в способности к генерализации на более сложные случаи без дополнительных компонентов.

2.2.3. Архитектура U-Net

Изначально предложенная для задач биомедицинской сегментации, архитектура U-Net зарекомендовала себя и в задачах денойзинга. Её структура состоит из симметричного кодировщика и декодировщика, объединённых пропусками между соответствующими слоями. Это позволяет эффективно восстанавливать детали изображения, особенно при слабом сигнале.

Преимущества U-Net:

- сохраняет пространственные признаки даже при сильной компрессии;
- отлично справляется с текстурными и контурными структурами;
- подходит для малозумных и сильно зашумлённых изображений.

2.2.4. GAN для удаления шума

Генеративно-сопоставительные сети (GAN) используются не только для генерации изображений, но и для улучшения их качества. В контексте денойзинга применяется подход, при котором генератор создаёт очищенное изображение, а дискриминатор определяет, насколько оно «реалистично».

Примеры:

Noise2Noise, Noise2Void, Noise2Self — архитектуры, обучающиеся без чистых эталонных изображений, что особенно полезно в медицине и астрофизике, где чистые данные получить трудно.

Плюсы:

- GAN-сети способны создавать фотореалистичные результаты.
- могут обобщать сложные текстуры и шумовые характеристики.

Минусы:

- трудны в обучении;
- подвержены нестабильности и эффекту «галлюцинаций» (генерации деталей, которых изначально не было).

2.2.5. Transformer-базированные архитектуры

В последние годы получили распространение визуальные трансформеры (ViT) и гибридные модели, сочетающие CNN и self-attention. Их преимущество — способность учитывать глобальный контекст изображения.

Примеры:

Restormer — модель, использующая модифицированный self-attention для восстановления изображений с шумами и артефактами.

Uformer — гибридный денойзер, объединяющий свёртки и трансформеры.

В таблице 2 представлено сравнение нейросетевых подходов в обработке изображений.

Таблица 2 - Сравнение нейросетевых подходов

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.2>

№ п/п	Метод	Преимущества	Недостатки	Применение
1	DnCNN	Высокая точность, простота	Требуется чистых пар изображений	Универсальный денойзинг
2	Autoencoder	Быстрая и лёгкая реализация	Ограниченная гибкость	Простые задачи фильтрации
3	U-Net	Отличное восстановление деталей	Большой размер модели	Медицинские и спутниковые снимки
4	GAN	Реалистичные результаты	Трудность обучения	Эстетическая обработка, восстановление
5	Transformers	Учёт глобального контекста	Высокая вычислительная нагрузка	Критические и шумные данные

Преимущества нейросетевых методов заключаются в их способности адаптироваться к структуре шума и эффективно работать в условиях слабоконтрастных и сильно искажённых изображений. Однако такие методы требуют значительных вычислительных ресурсов, наличия обучающей выборки и тщательной настройки архитектуры [5].

Сверточный автоэнкодер

Для решения задачи удаления шума и восстановления изображений в данной работе предлагается использовать сверточный автоэнкодер. Данный класс нейросетевых архитектур сочетает преимущества сверточных сетей в извлечении пространственных признаков и автоэнкодеров в сжатии и восстановлении информации.

Архитектура модели включает два основных компонента [3]:

- Кодировщик (encoder) — последовательно применяет свёрточные слои с функцией активации ReLU и операции субдискретизации (max pooling), формируя компактное представление входного изображения. Его задача заключается в выделении ключевых признаков изображения при одновременном снижении размерности данных.

- Декодировщик (decoder) — симметричная часть сети, восстанавливающая изображение из сжатого представления. Для увеличения пространственного разрешения применяются операции upsampling или транспонированные свёртки (deconvolution).

- Код (Latent space / Bottleneck) — центральный слой («бутылочное горлышко»), содержащий сжатое представление входных данных. На этом уровне сохраняется только наиболее существенная информация, необходимая для восстановления исходного изображения.

Схематично структура автоэнкодера представлена на рисунке 1 [2].




Рисунок 1 - Структура автоэнкодера

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.3>

Связи между слоями (показаны пунктирными линиями) отражают передачу признаков и параметров обучения. При этом каждая пара слоёв кодировщика и декодировщика симметрично связана, что обеспечивает корректное восстановление структуры изображения.

Подробная структура предлагаемой архитектуры приведена в таблице 3.

Таблица 3 - Архитектура предложенного сверточного автоэнкодера

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.4>

Блок	Слой	Параметры	Размер выхода
Вход	Входной слой	128×128×1 (градации серого)	128×128×1
Кодировщик-1	Свёрточный слой + ReLU	32 фильтра, размер ядра 3×3, режим «same»	128×128×32
-	MaxPooling	окно 2×2	64×64×32
Кодировщик-2	Свёрточный слой + ReLU	64 фильтра, размер ядра 3×3	64×64×64
-	MaxPooling	окно 2×2	32×32×64
Узкое место (bottleneck)	Свёрточный слой + ReLU	128 фильтров, размер ядра 3×3	32×32×128
Декодировщик-1	Транспонированная свёртка + ReLU	64 фильтра, размер ядра 3×3, шаг 2	64×64×64
Декодировщик-2	Транспонированная свёртка + ReLU	32 фильтра, размер ядра 3×3, шаг 2	128×128×32
Выход	Свёрточный слой + Sigmoid	1 фильтр, размер ядра 3×3, режим «same»	128×128×1

Архитектура реализована в среде PyTorch. В качестве функции активации использована ReLU во внутренних слоях и Sigmoid на выходе. Применялись методы регуляризации: Dropout (0,2) в узком месте и Batch Normalization после свёрточных слоёв. Для оптимизации обучения использован алгоритм Adam со скоростью обучения $1 \cdot 10^{-3}$, инициализация весов выполнена по методу Xavier uniform.

Экспериментальная часть

Экспериментальные исследования направлены на проверку гипотезы о том, что использование сверточного автоэнкодера обеспечивает более высокое качество восстановления изображений по сравнению с традиционными методами фильтрации и рядом современных нейросетевых архитектур. Основными задачами эксперимента являются:

- количественная оценка эффективности автоэнкодера при удалении различных типов шума;
- сравнение результатов с классическими методами обработки (Гауссов фильтр, медианный фильтр, фильтр Винера, билатеральный фильтр, Non-Local Means);
- сопоставление с современными архитектурами глубокого обучения (DnCNN, U-Net);
- анализ применимости предложенного подхода к медицинским и телеметрическим данным.

Для обеспечения воспроизводимости эксперимента параметры классических фильтров были зафиксированы в таблице 4.

Таблица 4 - Конфигурации классических методов фильтрации

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.5>

Метод	Установленные параметры
Гауссов фильтр	окно 5×5 , $\sigma = 1,0$
Медианный фильтр	окно 3×3
Фильтр Винера	окно 5×5 , оценка дисперсии шума $\sigma^2 = 0,01$
Билатеральный фильтр	радиус = 5, $\sigma_s = 2$, $\sigma_r = 0,1$
Non-Local Means	размер патча 7×7 , окно поиска 21×21 , коэффициент сглаживания $h = 10$

Основные параметры используемых нейросетевых моделей представлены в таблице 5.

Таблица 5 - Основные параметры сравниваемых нейросетевых моделей

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.6>

Модель	Архитектура	Характеристики обучения
DnCNN	17 свёрточных слоёв (64 фильтра 3×3 , Batch Normalization, ReLU); выход — остаточный шум	CIFAR-10 (40 тыс. обучающая выборка, 10 тыс. валидационная); Adam ($lr = 1 \cdot 10^{-3}$); 50 эпох
U-Net	4 блока кодировщика и 4 блока декодировщика; наличие skip-соединений; число фильтров: 32–64–128–256	CIFAR-10 и реальные данные; Adam ($lr = 1 \cdot 10^{-4}$); 60 эпох
Autoencoder (предложенный)	см. таблицу 3	CIFAR-10 и реальные данные; Adam ($lr = 1 \cdot 10^{-3}$); 80 эпох

Для проведения экспериментов были использованы два типа данных:

1. Синтетические наборы изображений:

- набор CIFAR-10 (60 000 изображений 32×32),
- дополнительно сформированный набор искусственно зашумлённых изображений стандартных тестовых картинок (Lena, Barbara, Cameraman, Peppers и др.).

Для обучения использовалось 40 000 изображений, для валидации — 10 000 изображений, для тестирования — 10 000 изображений.

2. Реальные данные:

- 120 микроскопических изображений биологических образцов, предоставленных Бюро судебно-медицинской экспертизы г. Байконур;
- 80 телеметрических кадров с бортовой системы видеоконтроля (БСВК) ракеты-носителя «Союз-2.1а», включая изображения при различных условиях освещённости и передачи.

Все изображения были нормализованы до диапазона $[0,1]$ и масштабированы до 128×128 пикселей.

Предложенный автоэнкодер обучался на совокупности синтетических и реальных данных с использованием следующей конфигурации:

- оптимизатор: Adam, скорость обучения $1e-3$;
- количество эпох: 80;
- размер батча: 32;
- функция потерь: среднеквадратическая ошибка (MSE);
- аппаратная платформа: графический ускоритель NVIDIA RTX (8 ГБ).

Для объективной оценки качества восстановления изображений использовались следующие показатели:

- MSE (Mean Squared Error) — отражает среднюю квадратическую ошибку между эталонным и восстановленным изображением. Выбран как базовый критерий количественного сравнения.

- PSNR (Peak Signal-to-Noise Ratio) — характеризует отношение мощности сигнала к мощности шума. Используется в задачах обработки изображений как стандартная метрика качества.

- SSIM (Structural Similarity Index) — оценивает структурное сходство между изображениями с учётом яркости, контраста и текстурных особенностей. Включена в эксперимент, так как именно она наиболее полно соответствует восприятию изображений человеком.

Таким образом, комбинация MSE, PSNR и SSIM позволяет комплексно оценить эффективность метода: от точности числового совпадения до сохранения визуальных и структурных характеристик.

Для повышения достоверности результатов была проведена статистическая обработка экспериментальных данных.

Пример усреднённых показателей и разброса значений (стандартное отклонение) приведён в таблице 6.

Таблица 6 - Средние значения и разброс метрик по тестовой выборке

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.7>

Метод	MSE (cp.)	MSE (σ)	PSNR (cp.)	PSNR (σ)	SSIM (cp.)	SSIM (σ)
Гауссов фильтр	0,0152	0,0021	26,8	1,4	0,74	0,05
Медианный фильтр	0,0129	0,0019	27,5	1,2	0,77	0,04
Фильтр Винера	0,0108	0,0017	28,3	1,0	0,79	0,03
Non-Local Means	0,0078	0,0012	30,4	0,9	0,85	0,02
U-Net	0,0061	0,0008	32,1	0,7	0,90	0,01
автоэнкодер (CNN)	0,0056	0,0006	32,7	0,6	0,91	0,01

Анализ таблицы показывает, что автоэнкодер демонстрирует не только минимальное среднее значение MSE, но и наименьшее стандартное отклонение по всем метрикам, что указывает на устойчивость модели к вариациям входных данных.

Задача повышения качества изображений приобретает особую значимость в прикладных областях, связанных с обработкой телеметрических данных, получаемых с бортовых камер, а также микроскопических изображений, используемых в экспертной и медицинской практике. Кроме численных метрик, были получены визуальные результаты (рисунки 2 – 5), демонстрирующие восстановление изображений, поврежденных гауссовским и импульсным шумом.

В рамках данного исследования в качестве источника реальных данных были использованы микроскопические изображения легких, предоставленные Бюро судебно-медицинской экспертизы г. Байконур (рисунки 2, 3). Визуальный анализ подтверждает, что предложенный автоэнкодер лучше сохраняет границы объектов и текстурные структуры по сравнению с традиционными фильтрами.

На рисунках 2 и 3 изображены микроскопические снимки легких до и после фильтрации.




Рисунок 2 - Изображение до фильтрации
DOI: <https://doi.org/10.60797/IRJ.2025.160.34.8>




Рисунок 3 - Изображение после фильтрации
DOI: <https://doi.org/10.60797/IRJ.2025.160.34.9>

Бюро судебно-медицинской экспертизы (БСМЭ) представляет собой специализированное государственное учреждение, осуществляющее судебно-экспертную деятельность, включая морфологические исследования биологических образцов. В ходе повседневной работы эксперты учреждения регулярно анализируют микроскопические изображения, и достоверность их заключений во многом зависит от качества визуального материала.

Однако на практике получаемые изображения часто характеризуются наличием различных искажений — шумов, размытости, пониженного контраста и других артефактов, обусловленных как техническими ограничениями микроскопического оборудования, так и условиями съёмки. Эти факторы затрудняют визуальную интерпретацию и автоматизированную обработку изображений, снижая точность диагностических и экспертных выводов.

Помимо анализа качества восстановления микроскопических изображений, особый интерес представляет применение предложенного подхода к задачам обработки телеметрической информации. В частности, рассмотрен пример изображений, полученных с бортовой системы видеоконтроля (БСВК) ракетно-космического комплекса.

Телеметрические кадры характеризуются низким уровнем сигнала, наличием различных видов шумов и искажений, обусловленных условиями передачи и особенностями аппаратуры. Эти факторы затрудняют последующую

интерпретацию и могут приводить к потере критически важной информации о техническом состоянии ракеты-носителя.

Применение сверточного автоэнкодера для фильтрации изображений БСВК позволяет не только уменьшить уровень шума, но и сохранить структурно значимые элементы изображения (контуры конструктивных узлов, мелкие детали), что существенно повышает достоверность анализа.

На рисунках 4 и 5 представлены снимки с бортовой системы видеоконтроля (БСВК) ракеты-носителя «Союз – 2.1а», выполненные 28 апреля 2016 года. Рисунки соответственно до и после фильтрации. Видно, что предложенный метод обеспечивает подавление шума при одновременном сохранении информативного содержимого изображения.



Рисунок 4 - Запуск РН «Союз – 2.1а» 28.04.2016. Кадр до обработки
DOI: <https://doi.org/10.60797/IRJ.2025.160.34.10>



Рисунок 5 - Кадр после обработки
DOI: <https://doi.org/10.60797/IRJ.2025.160.34.11>

Результаты и их анализ

Для оценки качества фильтрации выбран метод среднеквадратической ошибки (MSE), который измеряет разницу между оригинальным и отфильтрованным изображением. Чем меньше значение MSE, тем лучше качество фильтрации.

$$MSE = 1/N \sum_1^N (I_{\text{ориг}} - I_{\text{фильтр}, i})^2 \quad (4)$$

где N — общее количество пикселей, $I_{\text{ориг}}$ — интенсивность пикселя в оригинале, $I_{\text{фильтр}, i}$ — интенсивность пикселя в обработанном изображении.

Результаты оценки качества фильтрации представлены на рисунке 6.




Рисунок 6 - Оценка качества фильтрации
DOI: <https://doi.org/10.60797/IRJ.2025.160.34.12>

Как видно, сверточный автоэнкодер показал наименьшие значения MSE при всех уровнях шума, что подтверждает его высокую эффективность в удалении шума и восстановлении изображений по сравнению с другими методами.

Помимо метрик качества (MSE, PSNR, SSIM), оценивались временные ресурсы обучения и обработки изображений. Результаты приведены в таблице 7.

Таблица 7 - Временные ресурсы обучения и обработки изображений

DOI: <https://doi.org/10.60797/IRJ.2025.160.34.13>

Модель	Число эпох	Общее время обучения мин	Среднее время одной эпохи, мин	Среднее время обработки одного изображения (128×128 пикселей), мс
Autoencoder (предложенный)	80	570	7	3,4
U-Net	60	852	14	7,9
DnCNN	50	468	9	5,1

Сравнительный анализ временных характеристик показал, что предложенный сверточный автоэнкодер требует меньше времени на обучение и демонстрирует более быстрое время обработки изображений по сравнению с архитектурой U-Net. По сравнению с архитектурой DnCNN показал наилучшее среднее время обработки одного изображения. Таким образом, модель обладает не только высоким качеством восстановления, но и высокой вычислительной эффективностью, что особенно важно в задачах обработки телеметрических и медицинских изображений в условиях ограниченных ресурсов.

Заключение

В ходе исследования проведён анализ традиционных и современных методов удаления шума и восстановления изображений в задачах медицинской диагностики и обработки телеметрических данных. Рассмотрены основные алгоритмические подходы (Гауссов фильтр, медианный фильтр, фильтр Винера, билатеральный фильтр, метод Non-Local Means), а также архитектуры глубокого обучения (DnCNN, автоэнкодеры, U-Net, GAN, трансформер-базированные модели).

Результаты экспериментов на синтетических и реальных данных (микроскопические изображения и телеметрические кадры) показали, что сверточный автоэнкодер обеспечивает наименьшее значение MSE и более высокие значения PSNR и SSIM по сравнению с традиционными методами. Это подтверждает его эффективность в задачах восстановления изображений при сохранении структурных деталей и снижении уровня артефактов.

Научная новизна работы: впервые предложено применение сверточного автоэнкодера для единой постановки задачи фильтрации изображений в двух прикладных областях — медицинской визуализации (микроскопические снимки) и телеметрической практике (кадры БСВК). Практическая значимость исследования заключается в возможности внедрения предложенного подхода в системы автоматизированного анализа медицинских данных и обработки телеметрических изображений, получаемых с бортовых камер космических аппаратов.

Дальнейшие исследования планируется направить на использование гибридных архитектур (U-Net + трансформеры), а также на обучение моделей с применением безэталонных методов (Noise2Noise, Noise2Void), что позволит расширить область применения нейросетевых решений при ограниченной доступности чистых данных.

Конфликт интересов

Не указан.

Рецензия

Все статьи проходят рецензирование. Но рецензент или автор статьи предпочли не публиковать рецензию к этой статье в открытом доступе. Рецензия может быть предоставлена компетентным органам по запросу.

Conflict of Interest

None declared.

Review

All articles are peer-reviewed. But the reviewer or the author of the article chose not to publish a review of this article in the public domain. The review can be provided to the competent authorities upon request.

Список литературы / References

1. Мосева Е.В. Методы фильтрации изображений в условиях зашумленности / Е.В. Мосева // Науковедение. — 2015. — Т. 7. — № 5. — С. 1–12.
2. Боршигов К. Автоэнкодеры: типы архитектур и применение / К. Боршигов // Neurohive – Нейронные сети. — 2018
3. Гришин И.И. Использование сверточных нейронных сетей для повышения качества изображений в системах технического зрения / И.И. Гришин, К.В. Дьяконов // Международный научный журнал «Медиаобразование». — 2025. — Т. 6. — № 4. — С. 45–55.
4. Коваленко А.С. Архитектура U-Net для подавления шума на изображениях с механизмами частотного и частотно-временного внимания / А.С. Коваленко // CyberLeninka. — 2024. — С. 51–62.

5. Кожевникова А.В. Физико-информированный сверточный автоэнкодер для фильтрации одиночных затуманенных/задымленных изображений / А.В. Кожевникова // CyberLeninka. — 2024. — С. 139–148.
6. Литвинов М.А. Применение сверточных нейронных сетей для улучшения качества медицинских изображений / М.А. Литвинов, И.И. Кудряшов // Информационные технологии и вычислительные системы. — 2022. — № 4. — С. 45–53.
7. Павлов В.А. Сравнение архитектур нейронных сетей для подавления мультипликативного шума на изображениях / В.А. Павлов, А.А. Белов, В.Т. Нгуен [и др.] // Компьютерная оптика. — 2024. — Т. 48. — № 3. — С. 425–431. — DOI: 10.18287/2412-6179-CO-1400.
8. Сергеев А.В. Методы глубокого обучения для восстановления изображений в системах видеонаблюдения / А.В. Сергеев, П.А. Кузнецов // Вестник МГТУ им. Н.Э. Баумана. Серия «Приборостроение». — 2023. — № 6. — С. 72–84.
9. Batson J. Noise2Self: Blind Denoising by Self-Supervision / J. Batson, L. Royer // Proc. ICML. — 2019. — P. 524–533.
10. Boucherit I. Reinforced Residual Encoder–Decoder Network for Image Denoising via Deeper Encoding and Balanced Skip Connections / I. Boucherit, H. Kheddar // Big Data and Cognitive Computing. — 2025. — Vol. 9. — № 4. — Article 82. — DOI: 10.3390/bdcc9040082.
11. Chen C. Self-Supervised Learning for Medical Image Denoising without Reference Images / C. Chen, C. Qiao, Y. Xie [et al.] // IEEE Trans. Med. Imaging. — 2021. — Vol. 40. — № 12. — P. 3902–3913.
12. Gao X. A Denoising Method for Low-Dose CT Based on Improved Convolutional Neural Network / X. Gao, J. Zhou, W. Xu [et al.] // Signals. — 2025. — Vol. 6. — № 2. — Article 17. — DOI: 10.3390/signals6020017.
13. Krull A. Noise2Void — Learning Denoising from Single Noisy Images / A. Krull, T.-O. Buchholz, F. Jug // Proc. CVPR. — 2019. — P. 2129–2137.
14. Lehtinen J. Noise2Noise: Learning Image Restoration without Clean Data / J. Lehtinen, J. Munkberg, J. Hasselgren [et al.] // Proc. ICML. — 2018. — P. 2965–2974.
15. Prakash M. Deep Convolutional Neural Networks for Medical Image Denoising: A Review / M. Prakash, H. Patel, A. Singh // Biomedical Signal Processing and Control. — 2023. — Vol. 83. — Article 104655.
16. Tian C. Deep Learning on Image Denoising: An Overview / C. Tian, Y. Xu, W. Zuo [et al.] // Neural Networks. — 2020. — Vol. 131. — P. 251–275.
17. Zhang K. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising / K. Zhang, W. Zuo, Y. Chen [et al.] // IEEE Trans. Image Process. — 2017. — Vol. 26. — № 7. — P. 3142–3155.
18. Zhang K. FFDNet: Toward a Fast and Flexible Solution for CNN-based Image Denoising / K. Zhang, W. Zuo, L. Zhang // IEEE Trans. Image Process. — 2018. — Vol. 27. — № 9. — P. 4608–4622.
19. Zhang K. Learning Deep CNN Denoiser Prior for Image Restoration / K. Zhang, W. Zuo, S. Gu [et al.] // Proc. CVPR. — 2017. — P. 3929–3938.
20. Zamir S.W. Restormer: Efficient Transformer for High-Resolution Image Restoration / S.W. Zamir, A. Arora, S.H. Khan [et al.] // Proc. CVPR. — 2022. — P. 5728–5739.

Список литературы на английском языке / References in English

1. Moseva E.V. Metody fil'tracii izobrazhenij v usloviyah zashumlennosti [Methods of image filtering in noisy conditions] / E.V. Moseva // Naukovedenie [Science Studies]. — 2015. — Vol. 7. — № 5. — P. 1–12. [in Russian]
2. Borshigov K. Avtojenkodery: tipy arhitektur i primeneniye [Autoencoders: types of architectures and applications] / K. Borshigov // Neurohive – Nejronnye seti [Neurohive – Neural Networks]. — 2018 [in Russian]
3. Grishin I.I. Ispol'zovanie svertochnykh nejronnykh setej dlja povysheniya kachestva izobrazhenij v sistemah tehničeskogo zrenija [Using convolutional neural networks to improve image quality in machine vision systems] / I.I. Grishin, K.V. D'jakonov // Mezhdunarodnyj nauchnyj zhurnal «Mediaobrazovanie» [International Scientific Journal "Media Education"]. — 2025. — Vol. 6. — № 4. — P. 45–55. [in Russian]
4. Kovalenko A.S. Arhitektura U-Net dlja podavlenija shuma na izobrazhenijah s mehanizmami chastotnogo i chastotno-vremennogo vnimanija [U-Net architecture for noise suppression in images with frequency and frequency-time attention mechanisms] / A.S. Kovalenko // CyberLeninka. — 2024. — P. 51–62. [in Russian]
5. Kozhevnikova A.V. Fiziko-informirovannyj svertochnyj avtojenkoder dlja fil'tracii odinochnykh zatumanennykh/zadymlyennykh izobrazhenij [Physically informed convolution autoencoder for filtering single blurred/smoky images] / A.V. Kozhevnikova // CyberLeninka. — 2024. — P. 139–148. [in Russian]
6. Litvinov M.A. Primeneniye svertochnykh nejronnykh setej dlja uluchsheniya kachestva medicinskih izobrazhenij [Application of convolutional neural networks to improve the quality of medical images] / M.A. Litvinov, I.I. Kudrjashov // Informacionnye tehnologii i vychislitel'nye sistemy [Information Technologies and Computing Systems]. — 2022. — № 4. — P. 45–53. [in Russian]
7. Pavlov V.A. Sravneniye arhitektur nejronnykh setej dlja podavlenija mul'tiplikativnogo shuma na izobrazhenijah [Comparison of neural network architectures for suppressing multiplicative noise in images] / V.A. Pavlov, A.A. Belov, V.T. Nguen [et al.] // Komp'yuternaja optika [Computer Optics]. — 2024. — Vol. 48. — № 3. — P. 425–431. — DOI: 10.18287/2412-6179-CO-1400. [in Russian]
8. Sergeev A.V. Metody glubokogo obucheniya dlja vosstanovleniya izobrazhenij v sistemah videonabljudeniya [Deep learning methods for image restoration in video surveillance systems] / A.V. Sergeev, P.A. Kuznecov // Vestnik MGTU im. N.E. Bauman. Seriya «Priporostroyeniye» [Bulletin of the Bauman Moscow State Technical University. "Instrument Engineering" Series]. — 2023. — № 6. — P. 72–84. [in Russian]
9. Batson J. Noise2Self: Blind Denoising by Self-Supervision / J. Batson, L. Royer // Proc. ICML. — 2019. — P. 524–533.

10. Boucherit I. Reinforced Residual Encoder–Decoder Network for Image Denoising via Deeper Encoding and Balanced Skip Connections / I. Boucherit, H. Kheddar // *Big Data and Cognitive Computing*. — 2025. — Vol. 9. — № 4. — Article 82. — DOI: 10.3390/bdcc9040082.
11. Chen C. Self-Supervised Learning for Medical Image Denoising without Reference Images / C. Chen, C. Qiao, Y. Xie [et al.] // *IEEE Trans. Med. Imaging*. — 2021. — Vol. 40. — № 12. — P. 3902–3913.
12. Gao X. A Denoising Method for Low-Dose CT Based on Improved Convolutional Neural Network / X. Gao, J. Zhou, W. Xu [et al.] // *Signals*. — 2025. — Vol. 6. — № 2. — Article 17. — DOI: 10.3390/signals6020017.
13. Krull A. Noise2Void — Learning Denoising from Single Noisy Images / A. Krull, T.-O. Buchholz, F. Jug // *Proc. CVPR*. — 2019. — P. 2129–2137.
14. Lehtinen J. Noise2Noise: Learning Image Restoration without Clean Data / J. Lehtinen, J. Munkberg, J. Hasselgren [et al.] // *Proc. ICML*. — 2018. — P. 2965–2974.
15. Prakash M. Deep Convolutional Neural Networks for Medical Image Denoising: A Review / M. Prakash, H. Patel, A. Singh // *Biomedical Signal Processing and Control*. — 2023. — Vol. 83. — Article 104655.
16. Tian C. Deep Learning on Image Denoising: An Overview / C. Tian, Y. Xu, W. Zuo [et al.] // *Neural Networks*. — 2020. — Vol. 131. — P. 251–275.
17. Zhang K. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising / K. Zhang, W. Zuo, Y. Chen [et al.] // *IEEE Trans. Image Process.* — 2017. — Vol. 26. — № 7. — P. 3142–3155.
18. Zhang K. FFDNet: Toward a Fast and Flexible Solution for CNN-based Image Denoising / K. Zhang, W. Zuo, L. Zhang // *IEEE Trans. Image Process.* — 2018. — Vol. 27. — № 9. — P. 4608–4622.
19. Zhang K. Learning Deep CNN Denoiser Prior for Image Restoration / K. Zhang, W. Zuo, S. Gu [et al.] // *Proc. CVPR*. — 2017. — P. 3929–3938.
20. Zamir S.W. Restormer: Efficient Transformer for High-Resolution Image Restoration / S.W. Zamir, A. Arora, S.H. Khan [et al.] // *Proc. CVPR*. — 2022. — P. 5728–5739.