

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение  
высшего образования

«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ  
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г.ЧЕРНЫШЕВСКОГО»

Кафедра информатики и программирования

**ВЛИЯНИЕ ШУМОВ НА СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ**

**АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ**

студента 4 курса 441 группы

направления 02.03.03 Математическое обеспечение и администрирование  
информационных систем

факультета компьютерных наук и информационных технологий

Севостьяновой Марии Борисовны

Научный руководитель:

Старший преподаватель

Е.Е.Лапшева

Зав. кафедрой:

к.ф.-м.н., доцент

М.В.Огнева

Саратов 2026

## **ВВЕДЕНИЕ**

**Актуальность темы.** Современные системы компьютерного зрения активно применяются в задачах автоматической классификации изображений, видеонаблюдения, медицинской диагностики, автономного транспорта и промышленного контроля. В основе большинства подобных решений лежат сверточные нейронные сети (CNN), демонстрирующие высокую точность при обработке визуальных данных. Однако эффективность таких моделей во многом зависит от качества входных изображений.

В реальных условиях изображения нередко содержат различные искажения: шум сенсора, артефакты передачи данных, дефекты сжатия, недостаточную освещённость и другие виды деградации. Даже незначительные изменения структуры изображения могут приводить к ухудшению качества выделяемых признаков и, как следствие, снижению точности классификации. Особенно заметно данная проблема проявляется в случаях, когда модель обучается на чистых данных, а на этапе эксплуатации сталкивается с зашумлёнными изображениями.

Исследование устойчивости сверточных нейронных сетей к шумовым искажениям представляет практический интерес как с точки зрения повышения надёжности моделей машинного обучения, так и с точки зрения понимания особенностей формирования признаков представлений в глубоких нейронных сетях [1]. Анализ поведения различных архитектур в условиях искажённых данных позволяет определить наиболее устойчивые подходы к построению CNN и выявить методы повышения качества классификации в неблагоприятных условиях.

**Цель бакалаврской работы** является исследование влияния различных типов шумовых искажений на качество работы сверточных нейронных сетей, а также анализ эффективности архитектурных и обучающих подходов, направленных на повышение устойчивости моделей.

Для достижения поставленной цели были поставлены **следующие задачи:**

1. Изучить архитектурные принципы сверточных нейронных сетей, выделив компоненты, наиболее подверженные влиянию шума.
2. Изучить основные типы шумов цифровых изображений, их физическую природу и математические модели.
3. Проанализировать существующие методы повышения устойчивости CNN к шуму.
4. Реализовать программную среду для проведения экспериментального исследования.
5. Провести сравнительный анализ различных архитектур CNN при работе с зашумлёнными изображениями.
6. Оценить влияние типа шума, уровня его интенсивности и режима обучения на итоговые показатели качества классификации.

**Методологические основы** исследования в области сверточных нейронных сетей и устойчивости к шуму представлены в работах Дмитрия Намиота и Владимира Романова [1], Иэна Гудфеллоу, Йошуа Бенджио и Аарона Курвилль [2], Дмитрия Маршалко и Ольги Кубанских [3], Константина Курочка и Константина Панарина [4], Франсуа Шолле [5], Рафаэля Карлоса Гонсалеса и Ричарда Эдварда Вудса [6].

**Практическая значимость бакалаврской работы** заключается в разработке программной среды для полного факторного эксперимента по исследованию влияния шума на CNN, результаты которого могут быть использованы при проектировании систем компьютерного зрения, функционирующих в условиях зашумлённых входных данных.

**Структура и объём работы.** Бакалаврская работа состоит из введения, 5 разделов, заключения, списка использованных источников и 1 приложения. Общий объем работы – 75 страниц, из них 60 страниц – основное содержание, включая 5 рисунков и 16 таблиц, цифровой носитель в качестве приложения, список использованных источников информации – 23 наименований.

## КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ

**Первый раздел «Сверточные нейронные сети: архитектурные принципы и основные компоненты»** посвящен теоретическому обзору архитектуры CNN и анализу компонентов, наиболее подверженных влиянию шума.

Сверточные нейронные сети представляют собой специализированный класс глубоких нейронных сетей, разработанный для эффективной обработки данных с пространственной структурой. В отличие от полносвязных сетей, CNN используют принцип локальных рецептивных полей, что позволяет автоматически извлекать иерархию признаков: на начальных слоях – простые паттерны (края, углы), на глубоких – семантические компоненты объектов. Фундаментальным строительным блоком является сверточный слой, выполняющий операцию дискретной свертки с набором обучаемых фильтров. В качестве функции активации в современных CNN наиболее широко применяется ReLU и её модификации (Leaky ReLU, Parametric ReLU); при этом ReLU имеет существенный недостаток в условиях шума: слабые полезные сигналы на фоне отрицательного шума могут быть полностью обнулены. Слои пулинга (максимальный и усредняющий) управляют размерностью представлений: максимальный пулинг уязвим к импульсному шуму, поскольку одиночный выброс в окне полностью определяет выход нейрона. Рассмотрены архитектурные концепции ResNet с остаточными связями, позволяющими сохранять «чистый» сигнал в обход искажающих слоёв, а также механизмы нормализации (Batch Normalization, Group Normalization, Instance Normalization) и внимания. Отдельно разобраны проблемы обучения глубоких сетей: переобучение и методы его преодоления – регуляризация, Dropout, аугментация данных.

**Второй раздел «Шум в изображениях: понятия, источники, модели»** посвящен классификации шумов цифровых изображений, их физической природе, математическим моделям и метрикам оценки уровня искажений.

Шум в изображении определяется как случайные отклонения значений

пикселей от истинных, возникающие при захвате, передаче или обработке визуальных данных. Рассмотрены четыре основных типа шума. Аддитивный гауссовский шум описывается моделью  $p \sim \mathcal{N}(0, \sigma^2)$ , где  $p$  — он равномерно маскирует высокочастотные компоненты — мелкие детали и резкие границы, критически важные для первых сверточных слоёв. Импульсный шум («соль и перец») заменяет пиксели с вероятностью  $p$  на экстремальные значения (0 или 255) и особенно разрушителен для операции max-pooling. Мультипликативный (спекл) шум описывается моделью  $p \sim \mathcal{N}(1, \sigma^2)$  и характерен для радарных, ультразвуковых и лазерных систем; его особенность — неоднородная статистика по изображению. Пуассоновский (фотонный) шум имеет квантовую природу и характеризуется зависимостью дисперсии от яркости пикселя, что делает его особенно проблематичным для методов нормализации. Также выделен класс структурированных шумов (блочные артефакты JPEG, фиксированный паттерн-шум), опасных тем, что их коррелированная природа может быть ошибочно принята CNN за признаки объектов. В завершение раздела рассмотрены метрики оценки уровня шума: SNR, PSNR и SSIM, — каждая из которых отражает разные аспекты деградации и имеет свои преимущества в контексте анализа работы CNN.

**Третий раздел «Систематизация подходов к повышению устойчивости CNN к шуму»** посвящён обзору и классификации существующих методов защиты сверточных нейронных сетей от шумовых искажений.

Все подходы систематизированы по трём уровням воздействия. Методы уровня данных включают классическую фильтрацию (гауссовский, медианный и двусторонний фильтры) и аугментацию с добавлением шума, при которой модель намеренно обучается на зашумлённых изображениях, формируя инвариантные к шуму признаки. Рассмотрены современные автоматизированные методы аугментации — RandAugment и AutoAugment, а также применение генеративно-сопоставительных сетей (GAN) для создания реалистичных зашумлённых обучающих примеров. Архитектурные решения

охватывают модификации базовых компонентов CNN (увеличение ядра свёртки, замена max-pooling на смешанный пулинг), варианты нормализации (Group Normalization и Instance Normalization как более устойчивые альтернативы Batch Normalization) и механизмы пространственного и канального внимания. Методы уровня обучения включают традиционные регуляризаторы (, Dropout), специализированные функции потерь (Huber loss, контрастивные потери), а также мета-обучение и адаптивные стратегии, позволяющие модели подстраиваться под характеристики шума в процессе инференса.

**Четвёртый раздел «Программная реализация экспериментального исследования»** описывает инструментальную базу, датасет, предобработку данных, генерацию шумов и реализованные архитектуры CNN.

В качестве основной платформы для построения и обучения нейронных сетей использовались TensorFlow и Keras, обеспечивающие удобную сборку архитектур и воспроизводимость экспериментов. Для генерации шумов применялась библиотека scikit-image, для вычисления метрик классификации – scikit-learn, для работы с массивами данных – NumPy, для хранения результатов – pandas, для визуализации – Matplotlib и Seaborn, для ускорения параллельных вычислений – Joblib. В качестве датасета использовался CIFAR-10: 60 000 цветных изображений размером 32×32 пикселя, 10 классов объектов, из которых 50 000 отведено под обучение и 10 000 – под тестирование. Перед подачей в сеть значения пикселей приводились к диапазону [0; 1] путём деления на 255. Реализованы четыре типа шума с четырьмя уровнями интенсивности каждый (low, medium, high, ultrahigh): гауссовский, импульсный («соль и перец»), спекл и пуассоновский. Для сравнительного анализа реализованы четыре архитектуры CNN: базовая (Simple CNN), с пакетной нормализацией (BatchNorm CNN), с усиленной регуляризацией через Dropout (Dropout CNN) и ResNet с остаточными связями. Эксперимент построен по схеме четырех режимов обучения и тестирования: cleancalen, clean → noisy, noisy → clean и noisy → noisy.

**Пятый раздел «Анализ результатов экспериментального исследования»** посвящён разбору результатов полного факторного эксперимента, включавшего 768 запусков моделей при различных комбинациях архитектур, типов шума, уровней интенсивности и режимов обучения.

В первую очередь была оценена базовая производительность всех четырёх архитектур на чистых данных без каких-либо искажений. Это позволило установить точку отсчёта для последующего сравнения и убедиться, что различия в результатах обусловлены именно влиянием шума, а не исходными различиями в качестве моделей.

Далее проведён анализ по трём режимам обучения и тестирования. В режиме clean → noisy (обучение на чистых данных, тестирование на зашумлённых) зафиксировано наиболее значительное падение точности с ростом интенсивности шума. Данный сценарий наиболее близок к реальным условиям эксплуатации систем компьютерного зрения, когда модель разрабатывается в лабораторных условиях, а затем сталкивается с зашумлёнными входными данными. В режиме noisy → clean (обучение на зашумлённых, тестирование на чистых) все модели сохраняли приемлемую точность, что свидетельствует о том, что обучение на зашумлённых данных формирует более обобщённые признаки и не ухудшает распознавание чистых изображений. В режиме noisy → noisy установлено ключевое для работы наблюдение: точность классификации возрастает на 15–25 процентных пунктов по сравнению со сценарием clean → noisy при тех же типе и уровне шума. Это подтверждает, что именно режим обучения, а не архитектура модели, является определяющим фактором устойчивости к шумовым искажениям.

При анализе влияния типа шума наиболее разрушительным оказался гауссовский – он равномерно деградирует весь частотный спектр изображения и тем самым наиболее сильно подавляет признаки, извлекаемые сверточными слоями. Наименее разрушительным оказался спекл-шум.

Пуассоновский шум проявил нелинейное поведение: при умеренном уровне интенсивности он действовал как неявная аугментация и практически не снижал точность, тогда как при высоких уровнях его влияние становилось существенным.

Среди архитектур ResNet показала наибольший разброс результатов в зависимости от условий эксперимента: в благоприятных режимах она превосходила остальные, однако в режиме clean→noisy при высокой интенсивности шума демонстрировала значительное падение. Simple CNN оказалась наиболее сбалансированной – её результаты были стабильны вне зависимости от типа и уровня шума. BatchNorm CNN стала наиболее уязвимой: механизм батч-нормализации, эффективный при совпадении статистик обучающих и тестовых данных, дестабилизировал работу сети при их расхождении, что характерно именно для сценария с зашумлёнными тестовыми данными.

Завершающим этапом стал анализ ошибок классификации на уровне отдельных классов с использованием матриц ошибок и метрики F1. Классы «автомобиль» и «грузовик» продемонстрировали наибольшую устойчивость к шуму – предположительно благодаря чётким геометрическим контурам и однородным текстурным поверхностям, которые сохраняются даже при значительном зашумлении. Классы «кошка», «птица» и «собака» оказались наиболее уязвимыми: высокая вариативность поз, форм и текстур этих объектов делает их признаки чувствительными к любым искажениям, а шум дополнительно затрудняет разграничение визуально похожих классов между собой.

## ЗАКЛЮЧЕНИЕ

Цель работы была успешно достигнута: проведено экспериментальное исследование влияния шумовых искажений на качество работы сверточных нейронных сетей, реализована программная среда для полного факторного эксперимента с 768 запусками моделей.

В рамках теоретической части работы были изучены архитектурные принципы сверточных нейронных сетей и выделены компоненты, наиболее подверженные влиянию шума, в частности функция активации ReLU, слой пулинга и механизмы нормализации. Рассмотрены основные типы шумов цифровых изображений – гауссовский, импульсный («соль и перец»), спекл и пуассоновский, их физическая природа и математические модели. Также проведён анализ существующих методов повышения устойчивости CNN к шуму, которые были разделены на методы уровня данных, архитектурные решения и методы уровня обучения.

Экспериментально установлено, что ключевым фактором устойчивости является режим обучения: обучение на зашумлённых данных повышает точность классификации на 15–25 процентных пунктов по сравнению со сценарием, когда модель обучается на чистых данных, а тестируется на зашумлённых. Наиболее разрушительным оказался гауссовский шум, наиболее мягким – спекл. Пуассоновский шум проявил нелинейное поведение: умеренный уровень интенсивности действовал как неявная аугментация.

Среди архитектур ResNet показала наибольший разброс результатов, Simple CNN – наиболее сбалансированная, BatchNorm CNN – наиболее уязвимая. Анализ per-class F1 выявил, что automobile и truck наиболее устойчивы к шуму, тогда как cat, bird и dog – наиболее уязвимы.

Полученные результаты могут быть использованы при проектировании систем компьютерного зрения, функционирующих в условиях зашумлённых входных данных.

### **Основные источники информации:**

1. Д.Е. Намиот, В.Ю. Романов Об улучшении робастности моделей машинного обучения // International Journal of Open Information Technologies – 2024. – Т.12 – №3
2. И. Гудфеллоу, И. Бенджио, А. Курвилль Глубокое обучение / пер. с англ. — М.: ДМК Пресс, 2018.
3. Д.А. Маршалко, О.В. Кубанских АРХИТЕКТУРА СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ // Ученые записки Брянского государственного университета – 2019. – № 4. – С. 10–13.
4. К.С. Курочка, К.А. Панарин НЕЙРОСЕТЕВАЯ ОБРАБОТКА ДАННЫХ // учебно-методическое пособие – Гомель : ГГТУ им. П. О. Сухого – 2023
5. Ф. Шолле Глубокое обучение на Python // СПб.: Питер, 2018. — 400 с
6. Rafael C. Gonzalez, Richard E. Woods Digital Image Processing // London : Pearson – 2018