

Министерство науки и высшего образования Российской Федерации
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Рязанский государственный радиотехнический университет
имени В.Ф. Уткина»

На правах рукописи



Чинь Ван Тоан

**АЛГОРИТМЫ ВЕЙВЛЕТ-ФИЛЬТРАЦИИ И НЕЙРОСЕТЕВОЙ
ОБРАБОТКИ ЗАШУМЛЕННЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ
УСИЛЕНИЯ НИЗКОЧАСТОТНЫХ КОМПОНЕНТ**

Специальность: 2.3.1. Системный анализ, управление
и обработка информации, статистика

ДИССЕРТАЦИЯ

на соискание ученой степени
кандидата технических наук

Научный руководитель
доктор технических наук, профессор,
Бехтин Юрий Станиславович

Рязань 2026

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	6
ГЛАВА 1. ОБЗОР МЕТОДОВ И АЛГОРИТМОВ АНАЛИЗА И ФИЛЬТРАЦИИ ЗАШУМЛЕННЫХ ИЗОБРАЖЕНИЙ	13
1.1 Анализ природы и математической модели мультипликативного шума	13
1.2 Методы фильтрации спекл-шума	15
1.2.1 Методы пространственной фильтрации.....	15
1.2.2 Методы частотной фильтрации	21
1.2.3 Методы фильтрации на основе глубокого обучения	23
1.3 Метод фильтрации на основе вейвлет-преобразования	27
1.3.1 Обоснование выбора вейвлет-преобразования	27
1.3.2 Математические основы вейвлет-преобразования	29
1.3.3 Выбор типа вейвлета	36
1.3.4 Выбор уровня вейвлет-декомпозиции.....	40
1.3.5 Пороговая обработка вейвлет-коэффициентов	42
1.4 Статистическое моделирование методов фильтрации спекл-шума	45
1.4.1 Статистическое моделирование	45
1.4.2 Система критериев оценки качества изображений	47
1.4.3 Результаты статистического моделирования	50
1.5 Постановка задачи.....	57
1.6 Выводы по первой главе.....	61
ГЛАВА 2. АЛГОРИТМЫ ВЕЙВЛЕТ-АНАЛИЗА И ОБРАБОТКИ ЗАШУМЛЕННЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ УСИЛЕНИЯ НИЗКОЧАСТОТНЫХ КОМПОНЕНТ	63

2.1 Модифицированный алгоритм пороговой обработки вейвлет-коэффициентов с усилением НЧК в высокочастотных субполосах.....	63
2.1.1 Алгоритм пороговой обработки вейвлет-коэффициентов	63
2.1.2 Результаты моделирования	66
2.2 Адаптивный алгоритм пороговой обработки вейвлет-коэффициентов с локальной оценкой дисперсии шума с усилением НЧК	70
2.2.1 Адаптивный алгоритм пороговой обработки вейвлет-коэффициентов	70
2.2.2 Результаты моделирования	72
2.3 Алгоритмы комбинированной фильтрации спекл-шума с усилением НЧК в высокочастотных субполосах.....	76
2.3.1 Комбинирование пространственных и частотных методов фильтрации спекл-шума	76
2.3.2 Комбинированная фильтрация спекл-шума на основе текстурного анализа.....	77
2.3.3 Комбинированная фильтрация спекл-шума на основе вейвлет-преобразования и метода нелокального усреднения	79
2.3.4 Результаты моделирования	81
2.4 Алгоритм фильтрации зашумленных изображений с использованием нейронной сети U-Net в области вейвлет-преобразования.....	87
2.4.1 Архитектура U-Net для обработки субполос вейвлет-коэффициентов	87
2.4.2 Алгоритм фильтрации зашумленных изображений с использованием нейронной сети U-Net.	90
2.4.3 Результаты моделирования	91

2.5 Выводы по второй главе	94
ГЛАВА 3. АЛГОРИТМЫ АНАЛИЗА И ФИЛЬТРАЦИИ ЗАШУМЛЕННЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ОБРАБОТКИ ПРОСТРАНСТВЕННО-ОРИЕНТИРОВАННЫХ ДЕРЕВЬЕВ ВЕЙВЛЕТ-ПРЕОБРАЗОВАНИЯ.....	96
3.1 Пространственно-ориентированные деревья вейвлет-преобразования...	96
3.2 Алгоритм обработки ПОД вейвлет-преобразования с использованием архитектуры рекуррентной нейронной сети LSTM	98
3.2.1 Архитектура RNN-LSTM для обработки ПОД	98
3.2.2 Алгоритм обработки ПОД с использованием RNN-LSTM.....	99
3.2.3 Результаты моделирования.....	100
3.3 Алгоритм обработки ПОД вейвлет-преобразования с использованием архитектуры нейронной сети трансформера	102
3.3.1 Архитектура трансформера для обработки ПОД.....	102
3.3.2 Алгоритм обработки ПОД с использованием трансформера	106
3.3.3 Результаты моделирования	106
3.4 Выводы по третьей главе.....	110
ГЛАВА 4. ПРОГРАММНАЯ РЕАЛИЗАЦИЯ РАЗРАБОТАННЫХ АЛГОРИТМОВ.....	112
4.1 Развитие программного комплекса IMPROC	112
4.1.1 Первая версия программного комплекса IMPROC 1.0	112
4.1.2 Вторая версия программного комплекса IMPROC 2.0	113
4.1.3 Обоснование необходимости перехода к IMPROC 3.0	114
4.2 Общая архитектура программного комплекса IMPROC 3.0.....	115
4.3 Режимы функционирования программного комплекса IMPROC 3.0	117

4.3.1 Режим обработки зашумленного изображения	117
4.3.2 Экспериментальный режим.....	120
4.4 Пользовательский интерфейс комплекса IMPROC 3.0	122
4.5 Применение программного комплекса IMPROC 3.0 в учебном и исследовательском процессе	129
4.5.1 Применение IMPROC 3.0 в учебном процессе	129
4.5.2 Применение IMPROC 3.0 в исследовательском процессе	130
4.6 Выводы по четвертой главе	132
ЗАКЛЮЧЕНИЕ	134
СПИСОК СОКРАЩЕНИЙ.....	136
СПИСОК ЛИТЕРАТУРЫ	137
ПРИЛОЖЕНИЕ.....	151
П1. Акты внедрения	151
П2. Свидетельства о государственной регистрации программы для ЭВМ .	155

ВВЕДЕНИЕ

Актуальность темы исследования. Наличие внутренних шумов датчиков оптического, радиолокационного и ультразвукового диапазонов и специфика формирования выходного сигнала с их помощью приводит к существенному снижению не только визуального качества изображений, но и эффективности алгоритмов автоматической вторичной обработки [1-4].

Анализ и обработка изображений, искажённых мультипликативным шумом, не является тривиальной задачей, поскольку интенсивность шумовой составляющей зависит от локальной яркости и статистических свойств изображения, что приводит к существенным искажениям не только в высокочастотных, но также и в низкочастотных участках спектра. [5-7]. Характерным примером мультипликативного характера искажений является спекл-шум, возникающий в когерентных системах формирования изображений вследствие интерференции отражённых или рассеянных волн [8-12].

Вейвлет-преобразование, благодаря способности обеспечивать локализацию сигналов одновременно в пространственной и частотной областях, является эффективным инструментом анализа и обработки изображений, в том числе для решения задач фильтрации шумов. В последние годы методы анализа и обработки изображений, основанные на применении нейронных сетей, также продемонстрировали относительно высокую эффективность в задачах компрессии и шумоподавления [33-34]. Тем не менее, пороговая обработка вейвлет-коэффициентов высокочастотных субполос относительно эффективна в случае аддитивных искажений, однако при мультипликативном шуме приводит к более существенному размытию границ объектов, потере мелких фрагментов и появлению большего числа артефактов [30-32]. С другой стороны, сочетание пространственной фильтрации с нейросетевой обработкой не всегда оказывается эффективным из-за сложности выбора архитектуры нейронной сети и ее обучения [88-92].

Одним из вариантов модификации традиционных алгоритмов вейвлет-фильтрации и нейросетевой обработки является усиление низкочастотных компонент (НЧК) спектра изображений с целью повышения отношения сигнал-шум

при предварительной обработке. Показано, что в определенных условиях добавление детерминированной низкочастотной составляющей полезного сигнала к его зашумленной версии приводит к устойчивости и сходимости алгоритмов оценивания параметров модифицированного сигнала и, следовательно, к повышению отношения оценок параметров искомого полезного сигнала к остаточному шуму после вычитания добавленной НЧК.

Таким образом, обоснование, разработка, исследование и программная реализация алгоритмов анализа и обработки изображений, искаженных мультипликативным шумом, на основе усиления НЧК при использовании вейвлет-преобразования и нейронных сетей представляют собой актуальную научно-техническую задачу.

Степень проработанности темы исследования. Существенный вклад в развитие классических методов фильтрации мультипликативного шума внесли Д. Куан [19], Дж. Гудман [5,6], Дж. С. Ли [15, 20], А. Лопес [21,22], К. Оливер [17], Р. Тузи [21-23], В. Фрост [24] и др.

Фундаментальные основы вейвлет-преобразования и методов вейвлет-фильтрации сформированы в работах С. Бюрруса [26], М. Веттерли [27], Б. Видаковича [28], И. Добеши [29], Д. Донохо [30-32], С. Малла [33, 34], Г. Стрэнга [55], М. Унзера [36] и других исследователей. Применительно к задаче фильтрации спекл-шума в изображениях существенный вклад внесли Б. Айацци [66], А. Аким [67], Л. Альпароне [66], Ф. Ардженти [68, 69], Т. Бьянки [70, 71], М. Мاستриани [72], Х. Се [73], С. Фуше [74] и другие авторы, предложившие байесовские, многомасштабные и гибридные методы фильтрации в вейвлет-области.

Из российских исследователей, работы которых непосредственно связаны с теоретическими аспектами вейвлет-преобразования и его практическими приложениями, в том числе с фильтрацией зашумлённых изображений, следует отметить К.А. Алексеева [39], Б.А. Алпатова [40], Ю.С. Бехтина [113-115, 117-120], В.В. Витязева [41], В.И. Воробьёва [42], А.В. Дворковича, В.П. Дворковича [43], Ю.К. Демьяновича [44], В.Ф. Кравченко [45], Л.В. Новикова [46], А.П. Петухова [47], А.Л. Приорова [48], А. М. Соифера [49], В.А. Фурсова [50] и др.

В последние годы активно развиваются и методы фильтрации зашумленных изображений на основе глубокого обучения, представленные в работах П. Ванга [104], Э. Далсассо [105], Г. Кьеркия [106], А. Тахера [107], К. Чжана [108] и др.

Целью исследования является обоснование, разработка, экспериментальное исследование и программная реализация алгоритмов обработки, анализа и фильтрации изображений, искаженных мультипликативным шумом, на основе усиления НЧК при использовании вейвлет-преобразования и нейронных сетей.

Для достижения поставленной цели в диссертационной работе решаются следующие **задачи**.

1. Сравнительный анализ и классификация существующих методов и алгоритмов анализа, обработки и фильтрации зашумленных изображений, в том числе с использованием вейвлет-преобразования и нейронных сетей.

2. Обоснование выделения НЧК зашумленного изображения и их добавления в высокочастотную область спектра для повышения эффективности алгоритмов анализа и обработки зашумленных изображений.

3. Разработка и исследование алгоритмов устранения шума на основе пороговой обработки вейвлет-коэффициентов с усилением НЧК в высокочастотных субполосах.

4. Разработка и исследование алгоритмов комбинированной вейвлет-фильтрации зашумленных изображений на основе их текстурного анализа.

5. Разработка и исследование алгоритмов фильтрации изображений, искаженных мультипликативным шумом, с использованием нейронных сетей на основе информации о пространственно-ориентированных деревьях (ПОД) вейвлет-преобразования.

Объектом исследования являются искаженные мультипликативным шумом изображения в градациях серого цвета, имеющие кусочно-регулярные структуры.

Предметом исследования являются алгоритмы анализа и обработки зашумленных изображений на основе вейвлет-преобразования и нейронных сетей.

Методы исследования. Для решения перечисленных задач использовались элементы теории вероятности и математической статистики, теории цифровой

обработки сигналов и изображений, теории вейвлет-преобразования, методы имитационного моделирования, машинного и глубокого обучения, а также инструменты программной инженерии.

Научная новизна

1. Разработан модифицированный алгоритм фильтрации зашумленных изображений на основе пороговой обработки вейвлет-коэффициентов с усилением НЧК в высокочастотных субполосах.

2. Разработан адаптивный алгоритм фильтрации зашумленных изображений на основе пороговой обработки вейвлет-коэффициентов с локальной оценкой дисперсии шума при усилении НЧК.

3. Разработан алгоритм фильтрации зашумленных изображений на основе модифицированного алгоритма пороговой вейвлет-обработки и фильтра Винера с использованием текстурного анализа.

4. Разработан алгоритм фильтрации зашумленных изображений на основе применения метода нелокального усреднения Non-Local Means (NLM) в области вейвлет-преобразования.

5. Разработан алгоритм фильтрации зашумленных изображений на основе применения архитектуры нейронной сети U-Net в области вейвлет-преобразования.

6. Разработаны алгоритмы фильтрации зашумленных изображений на основе обработки ПОД вейвлет-коэффициентов с использованием архитектур трансформера и рекуррентной нейронной сети LSTM.

Основные положения, выносимые на защиту

1. Обоснование усиления НЧК зашумленного изображения в высокочастотной области вейвлет-трансформанты для повышения эффективности фильтрации шума, что подтверждается результатами экспериментальных исследований разработанных алгоритмов анализа и обработки зашумленных изображений, которые позволяют повысить пиковое отношение сигнал-шум (ПОСШ) в среднем на 5,4 дБ, индекс структурного сходства (SSIM) – на 56 %, а также снизить

количество вносимых артефактов, оцениваемое по метрике оценки качества изображений Gradient Magnitude Similarity Deviation (GMSD), в среднем на 47 %.

2. Алгоритмы анализа и фильтрации зашумленных изображений на основе адаптивной пороговой обработки и комбинированной фильтрации с использованием фильтра Винера, метода NLM и нейронной сети U-Net позволяют повысить ПОСШ в среднем на 5,6 дБ, SSIM – на 59 %, а также снизить значение метрики GMSD в среднем на 49 %.

3. Алгоритмы анализа и фильтрации зашумленных изображений на основе обработки ПОД вейвлет-преобразования с помощью модифицированных архитектур нейронной сети RNN (LSTM) и трансформера позволяют повысить ПОСШ в среднем на 5,9 дБ, SSIM – на 60 %, а также снизить значение GMSD в среднем на 53 %.

Соответствие паспорту специальности. Диссертация соответствует паспорту специальности 2.3.1. «Системный анализ, управление и обработка информации, статистика» в части:

– пункту 4 «Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта»;

– пункту 12 «Визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации».

Достоверность и обоснованность полученных результатов подтверждены теоретическими выкладками, численными экспериментами на реальных и синтетических зашумленных изображениях, а также сравнительным анализом с известными методами фильтрации (медианный фильтр, фильтр Винера, фильтр Ли и др.) по объективным метрикам качества (ПОСШ, SSIM, GMSD и др.) и субъективной визуальной оценкой.

Практическая значимость. Разработанные алгоритмы могут быть использованы при анализе и обработке данных зашумленных изображений в задачах машинного зрения, дистанционного зондирования, контроля состояния

объектов, анализа природных и искусственных сцен, а также в других областях цифровой обработки изображений и сигналов.

Результаты работы внедрены в учебный процесс ФГБОУ ВО «Рязанский государственный радиотехнический университет им. В.Ф. Уткина» в материалы лекций, а также используются при проведении лабораторных и практических занятий по дисциплинам «Методы сжатия изображений» и «Предварительная обработка изображений». Отдельные результаты работы внедрены в разработки АО «Торговля и развитие электронных технологий E-STAR» (Социалистическая Республика Вьетнам).

Личное участие автора. Автору на правах соавтора принадлежат постановка задачи, разработка алгоритмов, изложенных в главах диссертации, а также компьютерное моделирование работы алгоритмов и анализ экспериментальных данных. Степень авторства подтверждается соответствующим заключением кафедры АИТУ РГРТУ.

Апробация работы. Основные результаты и положения диссертационной работы докладывались и обсуждались на 8 научно-технических конференциях, в том числе на 6 международных и 2 всероссийских: 34-й международной конференции по компьютерной графике и машинному зрению (Омск, 2024 г.); 9-й и 10-й всероссийских научно-технических конференциях «Актуальные проблемы современной науки и производства» (Рязань, 2024 и 2025 гг.); 8-м и 9-м международных научно-технических форумах «Современные технологии в науке и образовании» (Рязань, 2025 и 2026 гг.); 27-й международной конференции «Цифровая обработка сигналов и её применение» (Москва, 2025 г.); 7-й международной молодежной конференции по радиоэлектронике, электротехнике и энергетике (Москва, 2025 г.); 18-й международной научно-технической конференции «Опτικο-электронные приборы и устройства в системах распознавания образов и обработки изображений» (Курск, 2025 г.).

Публикации. По теме диссертации опубликовано 15 научных работ, в том числе 2 статьи, индексируемые в базе Scopus, 4 статьи в изданиях, входящих в перечень ВАК, 5 тезисов докладов на международных и всероссийских

конференциях, а также получено 4 свидетельства о государственной регистрации программ для ЭВМ, реализующих предложенные алгоритмы.

Структура и объем диссертации. Диссертационная работа состоит из введения, четырёх глав, заключения, списка сокращений, списка литературы и приложений. Диссертация содержит 158 страниц, в том числе 13 таблиц и 40 рисунков. Список использованной литературы содержит 150 наименований.

ГЛАВА 1. ОБЗОР МЕТОДОВ И АЛГОРИТМОВ АНАЛИЗА И ФИЛЬТРАЦИИ ЗАШУМЛЕННЫХ ИЗОБРАЖЕНИЙ

1.1 Анализ природы и математической модели мультипликативного шума

Мультипликативный шум является характерным видом флуктуаций интенсивности, возникающих при формировании изображений в когерентных системах визуализации [5-7]. Его физическая природа обусловлена интерференцией волн, рассеянных множеством неоднородностей среды или отражающих элементов поверхности, находящихся в пределах одного элемента разрешения. В результате случайного сложения таких волновых вкладов в регистрируемом изображении формируется зернистая структура, проявляющаяся в виде пространственно неоднородных изменений яркости [5-10].

В отличие от аддитивных шумов, вызванных электронными помехами, тепловыми флуктуациями или квантованием сигнала, мультипликативный шум возникает вследствие самого процесса когерентного формирования изображения. Поэтому его рассматривают не как внешнюю помеху, а как внутренне присущую особенность изображений, получаемых в системах с когерентным излучением или когерентным приёмом сигнала. К таким системам относятся радиолокаторы с синтезированной апертурой (РСА), ультразвуковые и лазерные системы визуализации, системы оптической когерентной томографии и др. [8-10].

Одним из наиболее распространённых примеров проявления мультипликативного шума являются РСА-изображения [16-18], где такой шум получил название «спекл-шум» (speckle). В таких изображениях интенсивность сигнала определяется суммарным вкладом большого числа элементарных рассеивателей, расположенных в пределах одной разрешающей ячейки. Случайные фазовые соотношения между ними приводят к конструктивной и деструктивной интерференции, вызывая локальные усиления и ослабления сигнала. В результате даже однородные участки сцены на РСА-изображениях приобретают выраженную зернистую структуру, затрудняющую визуальную интерпретацию и автоматическую обработку изображений [68-70, 72-76].

Степень выраженности спекл-шума зависит от ряда факторов, включая степень когерентности излучения, число рассеивателей в элементе разрешения, распределение их амплитуд и фаз, геометрию наблюдения, а также физические свойства исследуемого объекта или среды [5-10]. В случае РСА-изображений существенное значение имеют шероховатость поверхности, ориентация объектов относительно направления зондирования, диэлектрические свойства материалов и структура подстилающей поверхности [16-18]. В ультразвуковых и оптических системах аналогичную роль играют акустические или оптические неоднородности среды, определяющие характер рассеяния [8-10].

Для описания спекл-шума в цифровых изображениях используется мультипликативная модель, согласно которой интенсивность наблюдаемого или регистрируемого изображения в точке с координатами (i, j) представляется в виде [5-7]:

$$Y(i, j) = X(i, j) \times Z(i, j), \quad (1.1)$$

где $X(i, j)$ — интенсивность пикселя истинного (неискаженного) изображения, $Z(i, j)$ — случайная мультипликативная составляющая спекл-шума.

Статистическое описание спекл-шума зависит от условий формирования изображения и принятой модели рассеяния. Если в пределах одного элемента разрешения содержится большое число независимых рассеивателей, а их фазы можно считать случайными и равномерно распределёнными, то действительная и мнимая части результирующей комплексной амплитуды описываются нормальным распределением. В этом случае амплитуда сигнала подчиняется распределению Рэлея, а интенсивность при однократном наблюдении — экспоненциальному распределению.

При усреднении нескольких независимых наблюдений статистика спекл-шума изменяется. Для РСА-изображений интенсивность спекл-шума Z подчиняется гамма-распределению [16]:

$$p(Z) = \frac{L^L Z^{L-1} e^{-LZ}}{\Gamma(L)}, \quad Z \geq 0, L \geq 1, \quad (1.2)$$

где $\Gamma(\cdot)$ — гамма-функция, L — число независимых усредняемых обзоров одного и того же участка местности.

Статистические свойства спекл-шума существенно зависят от параметра L . В случае так называемого «полностью развитого» спекла предполагается, что

$$E[Z] = 1, \text{Var}[Z] = \frac{1}{L}, \quad (1.3)$$

где E — символ математического ожидания, Var — дисперсия спекл-шума.

При $L = 1$ распределение (1.2) становится экспоненциальным. С увеличением L распределение становится менее асимметричным и приближается к нормальному, а относительная дисперсия шума уменьшается.

Спекл-шум оказывает существенное влияние на качество РСА-изображений и результаты их интерпретации. Он снижает радиометрическую однородность областей, маскирует слабоконтрастные объекты, затрудняет выделение границ и ухудшает различимость мелких структурных элементов [16-18]. В РСА-изображениях это особенно важно при классификации земного покрова, оценке влажности почвы, мониторинге растительности, анализе состояния лесных массивов, а также при обнаружении малоразмерных объектов, например судов или транспортных средств, на фоне сложной подстилающей поверхности.

Таким образом, спекл-шум представляет собой одно из принципиальных ограничений при обработке изображений, непосредственно влияющее на точность, надёжность и детальность извлекаемой информации. В связи с этим задача его фильтрации при сохранении информативных структурных особенностей изображения является одной из ключевых задач обработки зашумленных изображений.

1.2 Методы фильтрации спекл-шума

1.2.1 Методы пространственной фильтрации

Методы пространственной фильтрации изображений основаны на непосредственной обработке значений пикселей в пространственной области [1-4, 77-82]. В отличие от частотных методов, в которых обработка выполняется в

спектральной области, например с использованием преобразования Фурье, пространственная фильтрация осуществляется непосредственно над исходным изображением путём применения локальных или нелокальных операций к пикселям. Основным принцип пространственной фильтрации состоит в замене значения каждого пикселя новым значением, вычисляемым на основе интенсивностей соседних пикселей. Такие методы широко используются для подавления шумов, сглаживания, повышения резкости, а также выделения границ и текстурных особенностей изображения [78, 79].

Одним из наиболее распространённых подходов является применение локальных фильтров, использующих фиксированную окрестность, обычно квадратное окно размера $n \times n$, вокруг каждого пикселя. Новое значение пикселя вычисляется по значениям элементов изображения, находящихся внутри данного окна. К числу наиболее известных локальных фильтров относятся усредняющий фильтр, уменьшающий шум за счёт усреднения значений в окрестности, но приводящий к размытию границ; медианный фильтр, устойчивый к импульсному шуму типа «соль и перец», поскольку вместо арифметического среднего использует медиану; а также фильтр Гаусса, выполняющий взвешенное усреднение, при котором больший вклад вносят пиксели, расположенные ближе к центру окна [76–78]. Преимуществами локальных фильтров являются простота реализации и, как следствие, высокое быстродействие. Однако такие методы, как правило, не учитывают структурные особенности изображения, что нередко приводит к потере деталей и размытию границ объектов [76–78].

Для преодоления указанных ограничений применяются адаптивные фильтры, основанные на использовании локальных статистических характеристик изображения, таких как среднее значение, дисперсия и стандартное отклонение. В отличие от обычных локальных фильтров, параметры адаптивных фильтров изменяются в зависимости от текстуры изображения. Примером такого подхода является адаптивный фильтр Винера, который обеспечивает эффективное подавление шума в однородных областях и лучшее сохранение деталей в областях с высокой локальной дисперсией, например, вблизи границ объектов. Ниже

рассматриваются адаптивные фильтры, ставшие классическими при обработке изображений, искаженных спекл-шумом. Во многих подходах перед применением таких фильтров зашумленные изображения подвергается логарифмированию, что позволяет преобразовать мультипликативную модель спекл-шума к аддитивной модели [19–24].

Фильтр Куана (Kuan). Для каждого пикселя с координатами (i, j) в скользящем окне размером $n \times n$ вычисляется выходное значение по формуле [19]:

$$\hat{X}(i, j) = \mu_Y + \frac{\sigma_X^2 (Y(i, j) - \mu_Y)}{\sigma_X^2 + (\mu_Y^2 + \sigma_X^2) / L}, \quad \sigma_X^2 = \frac{L\sigma_Y^2 - \mu_Y^2}{L+1} \quad (1.4)$$

или

$$\hat{X}(i, j) = \mu_Y + W(Y(i, j) - \mu_Y), \quad (1.5)$$

где W — адаптивная весовая функция, определяющая степень сглаживания, μ_Y — локальное среднее значение наблюдаемого изображения Y в скользящем окне размера $n \times n$, окружающем пиксель (i, j) , σ_X^2 , σ_Y^2 — локальная дисперсия истинного и наблюдаемого изображения, L — число обзоров.

Весовая функция W определяется как:

$$W = \frac{1 - \frac{C_Z^2}{C_Y^2}}{1 + C_Z^2}, \quad (1.6)$$

где $C_Z = \frac{\sigma_Z}{\mu_Z}$ — коэффициент вариации шума, известный априорный параметр,

характеризующий уровень шума, $C_Y = \frac{\sigma_Y}{\mu_Y}$ — локальный коэффициент вариации в

окне, σ_Y — локальное среднеквадратическое отклонение наблюдаемого изображения, σ_Z — среднеквадратическое отклонение шума z .

Если значение коэффициента вариации высоко ($C_Y \gg C_Z$), то W приближается к 1, и исходное значение пикселя не меняется, что сохраняет резкость контуров и деталей. Если значение коэффициента вариации низко

$C_Y \approx C_Z$, то W приближается к 0, и происходит сильное усреднение, эффективно подавляющее шум.

Фильтр Ли (Lee). Фильтр Ли является упрощением фильтра Куана, полученным путем использования линейной аппроксимации (разложения в ряд Тейлора) мультипликативной модели шума, чтобы свести её к аддитивной форме [15, 20]. При этом адаптивная весовая функция определяется:

$$W = 1 - \frac{C_Z^2}{C_Y^2}. \quad (1.7)$$

Как и фильтр Куана, фильтр Ли изменяет степень сглаживания в зависимости от локальной вариативности изображения, чтобы сохранить детали и границы. Однако на практике фильтр Ли часто считается чуть более "агрессивным" в сглаживании.

Фильтр Винера (Wiener). Фильтр минимизирует среднеквадратическое отклонение (СКО) между истинным изображением и его оценкой [1–3, 76, 78]. Для локального окна вокруг пикселя формула фильтра выглядит так:

$$\hat{X}(i, j) = \mu_Y + \frac{\sigma_Y^2 - \sigma_Z^2}{\sigma_Y^2} (Y(i, j) - \mu_Y). \quad (1.8)$$

Если $\sigma_Y \gg \sigma_Z$ (на краях объектов), коэффициент перед скобкой близок к 1, и значение пикселя почти не меняется. Если $\sigma_Y \approx \sigma_Z$ (в однородных областях), результат стремится к среднему значению.

В отличие от фильтров Ли и Куана, которые чаще применяются для специфического спекл-шума, фильтр Винера широко применяется при аддитивном гауссовом шуме. Однако его можно применять к логарифмически преобразованным зашумленным изображениям (где спекл-шум становится приблизительно аддитивным) или после преобразования модели шума [19–24].

Фильтр Фроста (Frost). Фильтр Фроста является адаптивным экспоненциальным фильтром, разработанным специально для подавления спекл-шума в изображениях [24]. В отличие от фильтров Куана и Ли, которые используют линейную интерполяцию между локальным средним и исходным пикселем, Фрост применяет экспоненциально затухающие веса в зависимости от

расстояния до центра окна и локального контраста. Оценка оригинала \hat{X} для центрального пикселя (i, j) определяется как взвешенная сумма значений в окне Ω размером $m \times n$:

$$\hat{X}(i, j) = \frac{\sum_{m,n \in \Omega} w(m, n) Y(m, n)}{\sum_{m,n \in \Omega} w(m, n)}, \quad (1.9)$$

где $w(i, j)$ — весовые коэффициенты определяются по экспоненциальному закону:

$$w(m, n) = K \cdot \exp(-AC_Y^2(i, j) \cdot D(m, n)),$$

где K — нормировочная константа, обеспечивающая условие $\sum_{m,n \in \Omega} w(m, n) = 1$, A — константа скорости спада (коэффициент демпфирования), $C_Y^2(i, j)$ — локальный коэффициент вариации, вычисленный в центре окна, D — евклидово расстояние от центрального пикселя (i, j) до текущего (m, n) в окне.

Поведение фильтра Фроста полностью определяется величиной локального коэффициента вариации $C_Y^2(i, j)$, входящей в аргумент экспоненциальной весовой функции. В однородных областях, где $C_Y \rightarrow 0$ (мало деталей, преобладает шум), аргумент экспоненты стремится к нулю, что делает веса почти равномерными, и фильтр вырождается в обычное усреднение, эффективно подавляя спекл-шум. В неоднородных областях и на контурах, где C_Y велик, аргумент становится большим по модулю отрицательным числом, что заставляет экспоненту быстро спадать с расстоянием; в результате веса сосредотачиваются вблизи центра окна, фильтр практически не изменяет значение центрального пикселя (сохраняя контуры и детали), а его ядро становится очень узким. В промежуточных случаях при средних значениях C_Y формируется плавное экспоненциальное ядро, осуществляющее взвешенное усреднение с большим весом для ближайших соседей, что обеспечивает естественный переход между двумя описанными крайними режимами работы.

Таким образом, общий принцип рассмотренных локальных адаптивных фильтров заключается в использовании статистических характеристик, прежде всего математического ожидания и дисперсии, вычисляемых в ограниченной

окрестности каждого пикселя. Это обеспечивает их основные преимущества — лучшее сохранение границ и деталей по сравнению с простыми сглаживающими фильтрами, а также достаточно высокую устойчивость к шумам [19, 23, 24]. Однако фундаментальное ограничение таких методов связано с их локальным характером: они используют информацию только из непосредственной окрестности пикселя, что может быть недостаточным для эффективного разделения сложных текстур и шума, особенно в областях с низким контрастом. Одним из более продвинутых подходов, позволяющих преодолеть это ограничение, является метод нелокального усреднения NLM (Non-Local Means).

Метод NLM основан на предположении, что сходные локальные фрагменты изображения могут встречаться в различных его областях и использоваться для взаимного усреднения с целью подавления шума [81]. В отличие от локальных методов, учитывающих только ближайшее окружение пикселя, метод NLM использует сходство целых фрагментов изображения, которые могут находиться на значительном расстоянии друг от друга [81]. В основе метода лежит предположение о наличии в изображении повторяющихся структур и текстур. Восстановленное значение пикселя определяется как взвешенное среднее значений пикселей из других областей изображения, чьи окружающие фрагменты наиболее близки к рассматриваемому фрагменту. Согласно данному подходу, оценка истинного значения пикселя (i, j) определяется следующим образом:

$$\hat{X}(i, j) = \frac{1}{C(i, j)} \sum_{i, j \in \Omega} w(i, j; m, n) Y(m, n), \quad (1.10)$$

где Ω — область поиска похожих патчей, $w(i, j; m, n)$ — вес, отражающий степень сходства между патчами вокруг пикселей (i, j) и (m, n) , $C(i, j) = \sum_{i, j \in \Omega} w(i, j; m, n)$ — нормировочная константа.

Вес определяется по следующей формуле:

$$w(i, j; m, n) = \exp\left(-\frac{\|P_{i,i} - P_{m,n}\|_{2,h}^2}{h^2}\right), \quad (1.11)$$

где $P_{i,j}$, $P_{m,n}$ — патчи вокруг пикселей (i, j) и (m, n) , $\|P_{i,j} - P_{m,n}\|_{2,h}^2$ — взвешенная евклидова норма, h — параметр, контролирующий чувствительность к шуму.

Пространственная фильтрация представляет собой иерархию методов, эволюционирующих от простых к сложным, каждый из которых решает специфический класс задач, но обладает принципиальными ограничениями [76–81]. Базовые неадаптивные фильтры (усредняющий, медианный) обеспечивают скорость и простоту, однако жертвуют деталями из-за глобального применения одного ядра. Локальные адаптивные фильтры (Ли, Куана, Фроста) совершили качественный скачок, введя понятие адаптивности на основе локальной статистики окрестности, что позволило эффективно подавлять специфические шумы (например, мультипликативный шум) при сохранении контуров, но их фундаментальным ограничением остаётся локальность анализа, не позволяющая использовать глобальную избыточность изображения. Это ограничение преодолевает нелокальный метод, основанный на гипотезе самоподобия и взвешивающий вклад пикселей по сходству их окружений, что даёт наилучшее сохранение текстур при подавлении аддитивного шума, но за счёт экстремальных вычислительных затрат. Таким образом, пространственная парадигма в целом демонстрирует компромисс между точностью, универсальностью и сложностью, но остаётся слабоэффективной против системных искажений, имеющих чёткую частотную природу, таких как размытие или периодические артефакты. Это логично приводит к необходимости рассмотрения принципиально иного подхода — частотной (спектральной) фильтрации, которая оперирует не с пространственными окрестностями, а с представлением изображения в частотной области.

1.2.2 Методы частотной фильтрации

Методы частотной фильтрации изображений основаны на представлении изображения в частотной области, в которой анализируются и обрабатываются пространственные частоты, соответствующие различным структурным компонентам изображения [1–3, 76–78]. В отличие от методов пространственной фильтрации, работающих непосредственно со значениями яркости пикселей,

методы частотной фильтрации оперируют спектральными характеристиками изображения, что позволяет более гибко управлять процессами подавления шума, сглаживания и выделения контуров.

Переход в частотную область осуществляется с помощью математических преобразований, наиболее распространёнными из которых являются преобразование Фурье и вейвлет-преобразование. После выполнения фильтрации в частотной области осуществляется обратное преобразование, в результате чего формируется обработанное изображение в пространственной области. В качестве примера далее рассматривается метод частотной фильтрации, основанный на преобразовании Фурье. Методы фильтрации на основе вейвлет-преобразования будут рассмотрены отдельно в следующем подразделе [33–36, 44–49].

Преобразование Фурье позволяет представить изображение в виде совокупности гармонических составляющих различной частоты, амплитуды и фазы. Для цифровых изображений используется дискретное преобразование Фурье, а на практике — его вычислительно эффективная реализация, быстрое преобразование Фурье.

В частотной области низкие частоты соответствуют плавным изменениям яркости и крупномасштабным структурам изображения, тогда как высокие частоты отражают резкие перепады яркости, границы, мелкие детали и шумовые компоненты. Поэтому для подавления высокочастотного шума часто применяются низкочастотные фильтры. К их числу относятся идеальный низкочастотный фильтр, фильтр Гаусса и фильтр Баттерворта.

Основными преимуществами фильтрации на основе преобразования Фурье являются строгая математическая формализация и возможность точного управления спектральными характеристиками изображения. Однако такие методы основаны на глобальном анализе изображения, что ограничивает возможности учёта локальных особенностей и затрудняет обработку неоднородных по структуре областей [76–78].

1.2.3 Методы фильтрации на основе глубокого обучения

Развитие методов глубокого обучения привело к существенному прогрессу в области фильтрации и восстановления изображений [88, 89]. В отличие от классических методов шумоподавления, основанных на заранее заданных математических моделях и эвристических предположениях о характере шума, методы на основе нейронных сетей позволяют автоматически извлекать информативные признаки непосредственно из данных. Это обеспечивает их высокую эффективность при обработке сложных и слабо формализуемых искажений. Наиболее широкое распространение в задачах шумоподавления получили свёрточные нейронные сети (CNN) и архитектуры типа «энкодер–декодер», к которым относятся автоэнкодеры и U-Net.

Целью шумоподавления является получение оценки, максимально близкой к исходному изображению по заданному критерию качества [91, 107–111]. CNN применяются для решения данной задачи за счёт последовательного применения свёрточных фильтров, параметры которых обучаются на больших наборах данных. Одним из наиболее известных представителей данного подхода является модель DnCNN, в которой используется принцип остаточного обучения. В отличие от прямого восстановления изображения сеть обучается аппроксимировать шумовую составляющую:

$$R(Y; \theta) \approx n, \quad (1.12)$$

где R — отображение, реализуемое CNN с параметрами θ . Восстановление изображения осуществляется путём вычитания оценённого шума из входного изображения:

$$\hat{X} = Y - R(Y; \theta). \quad (1.13)$$

Архитектура DnCNN, как правило, включает последовательность свёрточных слоёв с ядрами малого размера 3×3 , функцией активации ReLU и слоями пакетной нормализации. Отсутствие операций подвыборки позволяет сохранять исходное пространственное разрешение изображения на всех уровнях сети. Использование остаточного обучения способствует ускорению сходимости,

повышению устойчивости процесса обучения и улучшению качества восстановления при различных уровнях шума.

Обучение CNN для шумоподавления осуществляется путём минимизации среднеквадратичной ошибки между истинным и оценённым шумом либо между восстановленным и эталонным изображениями. Функция потерь в общем виде может быть записана следующим образом:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \|R(Y_i; \Theta) - (Y_i - X_i)\|_2^2, \quad (1.14)$$

где N — количество обучающих примеров. Оптимизация параметров сети выполняется с использованием методов стохастического градиентного спуска или его адаптивных модификаций.

Наряду со CNN в задачах фильтрации изображений применяются архитектуры типа «энкодер–декодер», одной из базовых форм которых является автоэнкодер. Автоэнкодер представляет собой нейросетевую модель, в которой входное изображение преобразуется в компактное скрытое представление, а затем восстанавливается декодером. В задачах шумоподавления такая архитектура обучается восстанавливать изображение, максимально близкое к эталонному [88, 89].

Формально работа автоэнкодера может быть представлена следующим образом:

$$\begin{aligned} Z &= E(Y), \\ \hat{x} &= D(Z) = D(E(Y)), \end{aligned} \quad (1.15)$$

где Y — входное зашумлённое изображение, $E(\cdot)$ — отображение энкодера, $D(\cdot)$ — отображение декодера, Z — скрытое представление, \hat{X} — восстановленное изображение.

Особый интерес для задач шумоподавления представляет денойзинговый автоэнкодер (denoising autoencoder), в котором на вход сети подаётся зашумлённое изображение, а в качестве целевого выхода используется соответствующее чистое изображение. В этом случае обучение направлено на формирование такого скрытого представления, которое сохраняет существенные

признаки изображения и подавляет шумовую компоненту. Функция потерь обычно определяется как среднеквадратичная ошибка между восстановленным и эталонным изображениями:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \|X_i - \hat{X}_i\|_2^2, \quad (1.16)$$

где X_i — эталонное изображение, \hat{X}_i — результат восстановления, N — число обучающих примеров, θ — параметры сети.

На практике наибольшее распространение получили свёрточные автоэнкодеры (*convolutional autoencoders*), в которых полносвязные слои заменяются свёрточными операциями. Это позволяет учитывать пространственную структуру изображения, уменьшать число обучаемых параметров и эффективнее извлекать локальные признаки. Преимуществом автоэнкодеров является способность к обучению нелинейных преобразований, необходимых для подавления шума. Вместе с тем при чрезмерном сжатии скрытого представления возможно ухудшение качества восстановления и потеря мелких деталей.

Более сложной разновидностью архитектур типа «энкодер–декодер» является сеть U-Net, изначально предложенная для задач сегментации, но впоследствии успешно адаптированная для восстановления изображений и удаления шума. Отличительной особенностью U-Net является симметричная энкодер-декодерная структура с пропускными соединениями между соответствующими уровнями [92].

Сжимающая часть сети (энкодер, *encoder*) последовательно уменьшает пространственное разрешение изображения, извлекая всё более абстрактные признаки. На каждом уровне выполняются операции свёртки и нелинейного преобразования, за которыми следует подвыборка. Расширяющая часть (декодер), напротив, восстанавливает пространственное разрешение изображения с использованием операций апсемплинга и свёртки. Пропускные соединения обеспечивают передачу высокочастотной пространственной информации из

энкодера в декодер, что позволяет сохранять мелкие детали изображения, критически важные для эффективного шумоподавления [92, 107].

Формально отображение, реализуемое U-Net, может быть представлено в виде функции:

$$\hat{X} = F(Y; \theta), \quad (1.17)$$

где F — нелинейное отображение, параметризованное весами сети. В зависимости от конкретной реализации U-Net может быть обучена как на прямое восстановление изображения, так и на оценку шумовой компоненты по аналогии с остаточным обучением.

Обучение U-Net также основывается на минимизации функции потерь, чаще всего среднеквадратичной ошибки:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \|R(Y_i; \theta) - (Y_i - X_i)\|_2^2, \quad (1.18)$$

Благодаря многоуровневому представлению признаков и пропускным соединениям U-Net демонстрирует высокую эффективность при удалении шума различной природы, особенно в задачах, где важно сохранение структурных и текстурных деталей изображения. Однако по сравнению с классическими сетями CNN данная архитектура характеризуется более высокими вычислительными затратами.

Таким образом, методы фильтрации изображений на основе глубокого обучения, представленные CNN, автоэнкодерами и архитектурой U-Net, обеспечивают качественно новый уровень восстановления изображений по сравнению с традиционными алгоритмами. CNN, использующие остаточное обучение, эффективны при моделировании и оценке шумовой составляющей. Автоэнкодеры представляют собой базовые модели восстановления, основанные на формировании компактного скрытого представления входных данных. Архитектура U-Net, в свою очередь, обеспечивает более точное восстановление пространственной структуры изображения за счёт совместного использования локальных и глобальных признаков. Выбор конкретной архитектуры

определяется требованиями к качеству восстановления, вычислительными ресурсами и характеристиками обрабатываемых данных.

Однако данные подходы имеют и ряд недостатков. Основным ограничением является необходимость наличия больших размеченных наборов данных для обучения, а также высокая вычислительная стоимость как на этапе обучения, так и при практическом использовании. Кроме того, модели глубокого обучения часто обладают низкой интерпретируемостью, что затрудняет анализ причин их ошибок и коррекцию поведения.

Несмотря на указанные ограничения, методы фильтрации изображений на основе глубокого обучения продолжают активно развиваться и рассматриваются как одно из наиболее перспективных направлений в современной цифровой обработке изображений [88–90, 104–108].

1.3 Метод фильтрации на основе вейвлет-преобразования

1.3.1 Обоснование выбора вейвлет-преобразования

Вейвлет-преобразование обеспечивает кратномасштабное представление изображения в пространственно-частотной области [26–29, 33–36]. В отличие от классических спектральных методов, основанных на преобразовании Фурье и обеспечивающих только глобальное частотное представление сигнала, вейвлет-преобразование позволяет локализовать информацию как в пространственной области, так и по масштабу (частоте), что имеет принципиальное значение при анализе изображений [33–35, 51–55]. В основе вейвлет-преобразования лежат операции масштабирования и сдвига базисной функции, в результате чего формируется иерархическая система субполос коэффициентов, соответствующих различным пространственным частотам изображения. Низкочастотные вейвлет-коэффициенты описывают глобальную структуру изображения, тогда как высокочастотные коэффициенты в основном содержат информацию о локальных деталях, границах объектов и шумовых компонентах. Такое представление позволяет избирательно обрабатывать коэффициенты с целью подавления шума [29, 34, 53, 54].

Для практической реализации методов обработки изображений широко применяется дискретное вейвлет-преобразование (ДВП), которое, как правило, реализуется в виде т.н. быстрого вейвлет-преобразования (БВП, или алгоритма Малла) [26, 33, 34]. Данный алгоритм основан на каскадном применении низкочастотных и высокочастотных фильтров с последующей децимацией, а на этапе реконструкции — на интерполяции и обратной фильтрации. При выборе ортогонального или биортогонального вейвлет-базиса и корректной обработке граничных условий данный подход обеспечивает вычислительно эффективную декомпозицию изображения и его последующую реконструкцию. Благодаря вычислительной сложности, линейной по числу пикселей, и относительно небольшим требованиям к памяти метод пригоден для обработки изображений большого размера [26, 34, 35, 54].

Фильтрация шума в области вейвлет-трансформанты обычно осуществляется посредством пороговой обработки вейвлет-коэффициентов. Поскольку во многих случаях шумовые компоненты преимущественно проявляются в высокочастотных субполосах и соответствуют вейвлет-коэффициентам с малыми по модулю значениями, их подавление позволяет снизить уровень шума при сохранении основных структурных особенностей изображения. В связи с этим вейвлет-фильтрация, как правило, лучше сохраняет резкие границы и локальные структуры по сравнению с традиционными линейными пространственными фильтрами.

Следует отметить, что поскольку спекл-шум имеет мультипликативный характер, то вейвлет-преобразование может быть интегрировано с предварительными статистическими преобразованиями, переводящими мультипликативную шумовую составляющую в аддитивную модель. Это позволяет применять в области вейвлет-трансформанты методы и алгоритмы фильтрации, разработанные для аддитивного шума.

Таким образом, выбор вейвлет-преобразования для фильтрации спекл-шума в изображениях обусловлен следующими преимуществами:

- возможностью выполнения локального многомасштабного анализа, учитывающего пространственную неоднородность изображений [33, 34];
- возможностью эффективного разделения шумовых и структурных компонент изображения в пространстве вейвлет-коэффициентов [57, 65–71];
- способностью сохранять контуры и мелкие детали при подавлении спекл-шума [30–33, 65–71];
- вычислительной эффективностью и устойчивостью реконструкции изображения при использовании дискретного вейвлет-преобразования [54].

Перечисленные свойства позволяют рассматривать вейвлет-преобразование как теоретически обоснованный и эффективный инструмент решения задачи фильтрации спекл-шума в изображениях.

1.3.2 Математические основы вейвлет-преобразования

Эффективность применения вейвлет-преобразования в задачах обработки изображений (в том числе при фильтрации шума) во многом объясняется возможностью проведения кратномасштабного анализа (КМА), который объединяет представление сигнала в поддиапазонах, идеи квадратурной зеркальной фильтрации и пирамидальную обработку изображений [27–29, 33–38, 116]. В рамках КМА сигнал (изображение) рассматривается как элемент гильбертова пространства и представляется в виде суммы компонентов, соответствующих различным масштабам и ориентациям (в двумерном случае). Такое представление полезно для дальнейшей обработки: крупномасштабная структура изображения отделяется от мелкомасштабных деталей, среди которых обычно концентрируется значительная доля шумовой компоненты [34, 45, 30–32, 61, 65].

Пусть $L^2(\mathbb{R})$ обозначает гильбертово пространство квадратично интегрируемых функций со скалярным произведением:

$$\langle f, q \rangle = \int_{-\infty}^{\infty} f(x) \overline{q(x)} dx. \quad (1.19)$$

Кратномасштабный анализ с J уровнями формирует проекции функции $f \in L^2(\mathbb{R})$ на систему базисных функций, порожденных масштабированием и сдвигом одной

и той же масштабирующей функции $\varphi(t)$. Для целых $j \leq J$, $k \in \mathbb{Z}$ вводится в рассмотрение семейство функций $\varphi_{j,k}(x) = 2^{-j/2} \varphi(2^{-j}x - k)$, которое порождает субполоса аппроксимаций:

$$V_j = \left\{ \sum_{k \in F} c_k \varphi_{j,k} : F \subset \mathbb{Z}, c_k \in \mathbb{R} \right\} \quad (1.20)$$

Масштабирующая функция нормируется условием $\int_{-\infty}^{\infty} \varphi(x) dx = 1$, что обеспечивает корректную интерпретацию коэффициентов аппроксимации как усредненных (сглаженных) представлений сигнала на соответствующем масштабе. Проекционные коэффициенты аппроксимации на уровне j определяются как $a_{j,k} = \langle f, \varphi_{j,k} \rangle$.

Вейвлет-коэффициенты $d_{j,k} = \langle f, \psi_{j,k} \rangle$ интерпретируются как детализирующая компонента между аппроксимациями на последовательных уровнях и в терминах субполосного анализа соответствуют преимущественно высокочастотному содержанию. Ключевое свойство КМА формулируется через ортогональное дополнение субполосы V_j деталями:

$$V_j = V_{j+1} \oplus W_{j+1}, \quad (1.21)$$

где W_{j+1} — субполоса деталей, порожденное вейвлет-функцией $\psi(x)$ и ее масштабно-сдвиговыми копиями $\psi_{j,k} = 2^{-j/2} \psi(2^{-j}x - k)$.

Вложенность субполос аппроксимаций и согласованность масштабирования задаются стандартными свойствами КМА: $V_{j+1} \subset V_j$, инвариантность относительно масштабирования $f(x) \in V_j \Leftrightarrow f(2x) \in V_{j-1}$, плотность $\overline{\bigcup_{j \in \mathbb{Z}} V_j} = L^2(\mathbb{R})$ и $\bigcap_{j \in \mathbb{Z}} V_j = \{0\}$. В результате многоуровневой декомпозиции до уровня J пространство $L^2(\mathbb{R})$ представляется в виде прямой ортогональной суммы аппроксимаций на уровне J и всех детализирующих субполос более грубых уровней:

$$L^2(\mathbb{R}) = \left(\bigoplus_{j \leq J} W_j \right) \oplus V_J. \quad (1.22)$$

Соответственно, любая функция $f \in L^2(R)$ допускает разложение:

$$f(x) = \sum_k a_{j,k} \varphi_{j,k}(x) + \sum_{j \leq J} \sum_k d_{j,k} \psi_{j,k}(x). \quad (1.23)$$

В этом выражении «дуальность» функций φ и ψ отражает идею точного восстановления: аппроксимация задает «скелет» сигнала, а детализирующие компоненты (детали) на разных масштабах уточняют его локальные особенности. Для задач обработки изображений принципиально важно, что ψ имеет нулевое среднее (или эквивалентно содержит хотя бы один нулевой момент):

$$\int_{-\infty}^{\infty} \psi(x) dx = 0. \quad (1.24)$$

Это свойство обуславливает чувствительность соответствующих коэффициентов именно к локальным перепадам яркости и границам, а не к постоянной составляющей сигнала.

Практическая реализация вейвлет-декомпозиции обеспечивается его интерпретацией через банки фильтров. В рамках этой интерпретации масштабирующая функция представляется (описывается) в виде:

$$\varphi(x) = \sqrt{2} \sum_{n \in \mathbb{Z}} h[n] \varphi(2x - n), \quad (1.25)$$

а вейвлет-функция соответственно выражается через нее как:

$$\psi(x) = \sqrt{2} \sum_{n \in \mathbb{Z}} g[n] \varphi(2x - n), \quad (1.26)$$

где $\{h[n]\}$ и $\{g[n]\}$ — коэффициенты соответственно низкочастотного и высокочастотного фильтров. Нормировка коэффициентов удовлетворяет условиям $\sum_n h[n] = \sqrt{2}$ (или эквивалентной нормировке в принятой схеме) и $\sum_n g[n] = 0$, что обеспечивает нулевое среднее вейвлета. В дискретном случае это приводит к стандартным операциям анализа — фильтрации и прореживания — реализуемым в виде БВП. Пусть $a_j[k]$ — коэффициенты аппроксимации на уровне j , тогда:

$$a_{j+1}[k] = \sum_n h[n - 2k] a_j[n], \quad d_{j+1}[k] = \sum_n g[n - 2k] a_j[n]. \quad (1.27)$$

Таким образом, для получения аппроксимации на более грубом уровне выполняется низкочастотная фильтрация с последующей децимацией ($\downarrow 2$), а для

извлечения деталей — высокочастотная фильтрация той же аппроксимации с последующей децимацией. Обратное преобразование реализуется банком синтеза: интерполяцией (апсемплингом) ($\uparrow 2$) с последующей фильтрацией синтезирующими фильтрами $\tilde{h}[n]$, $\tilde{g}[n]$, что обеспечивает точное восстановление при выполнении условий идеальной реконструкции.

В ортогональном случае субполосы V_{j+1} и W_{j+1} ортогональны, а фильтры $\{h, g\}$ могут быть выбраны как квадратурно-зеркальные. В биортогональном случае используются две пары биортогональных фильтров ($\{h, g\}$ для анализа и $\{\tilde{h}, \tilde{g}\}$ для синтеза), что позволяет, в частности, строить симметричные (линейно-фазовые) схемы, удобные для обработки изображений [26, 34].

Поскольку на практике рассматриваются дискретные данные, описанная схема банков фильтров соответствует дискретному вейвлет-преобразованию. В одномерном случае БВП можно интерпретировать как древовидное разложение, где дальнейшая декомпозиция выполняется только для ветви аппроксимации. В двумерном случае (для изображений) БВП строится как последовательное применение одномерного банка фильтров по строкам и столбцам, что при сепарабельных базисах дает разложение по трем ориентациям деталей.

Пусть $I[m,n]$ — исходное изображение. Тогда на каждом уровне декомпозиции формируются четыре субполосы: LL , LH , HL , HH , соответствующие комбинациям низко- и высокочастотной фильтрации по горизонтали и вертикали. В случае сепарабельных вейвлет-базисов для уровня j эти субполосы могут быть записаны в терминах свертки следующим образом:

$$\begin{aligned} LL^{(j)} &= A^{(j-1)} h_x^{(j)} h_y^{(j)}, & LH^{(j)} &= A^{(j-1)} h_x^{(j)} g_y^{(j)}, \\ HL^{(j)} &= A^{(j-1)} g_x^{(j)} h_y^{(j)}, & HH^{(j)} &= A^{(j-1)} g_x^{(j)} g_y^{(j)}, \end{aligned} \quad (1.28)$$

где $A^{(0)} \equiv I$, $A^{(j)} \equiv LL^{(j)}$; h_x , h_y и g_x , g_y — фильтры, применяемые по горизонтали и вертикали соответственно (в простейшем сепарабельном случае их коэффициенты совпадают). В классическом ДВП после каждой операции фильтрации по соответствующей оси выполняется прореживание $\downarrow 2$. В результате субполоса LL представляет собой аппроксимацию (сглаженное изображение), а субполосы LH ,

HL и *HH* — детализирующие компоненты, чувствительные к изменениям яркости преимущественно в горизонтальном, вертикальном и диагональном направлениях соответственно (рис. 1.1). Многоуровневая декомпозиция строится рекурсивно (как правило, на каждом следующем уровне разлагается только субполоса *LL*), что формирует пирамидальную (древовидную) структуру представления изображения по масштабам. Именно такая структура в дальнейшем используется для построения процедур подавления шума, поскольку высокочастотные субполосы содержат значимую информацию о границах и текстурах, но одновременно наиболее чувствительны к шумовой компоненте [26, 35].

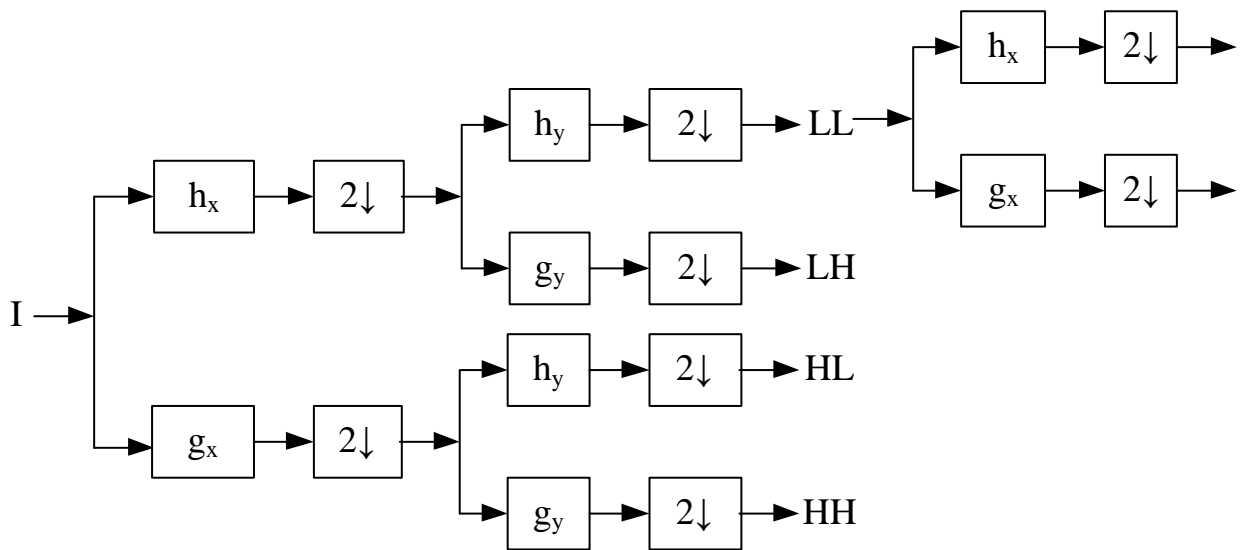


Рисунок 1.1 – Схема двумерного БВП

Классическая схема пирамидального преобразования с прореживанием не является инвариантной к сдвигам: небольшой сдвиг исходного сигнала (изображения) может приводить к заметному перераспределению коэффициентов из-за операции прореживания, что особенно критично при нелинейной обработке коэффициентов (например, при пороговой обработке) [35]. Для устранения этой особенности используется стационарное вейвлет-преобразование (СВП), в котором прореживание отсутствует, а переход между уровнями достигается растяжением фильтров. Формально алгоритм задается следующим образом. Положим $a_0[n] = x[n]$. На уровне $j \geq 1$ определяются модифицированные фильтры $h^{(j)}$ и $g^{(j)}$, получаемые путем вставки $(2^{j-1} - 1)$ нулей между каждой парой коэффициентов исходных фильтров h и g соответственно [34, 54, 62]. Тогда

коэффициенты аппроксимации и деталей вычисляются свертками без изменения размера:

$$a_j[n] = \sum_k h^{(j)}[k] a_{j-1}[n-k], \quad d_j[n] = \sum_k g^{(j)}[k] a_{j-1}[n-k]. \quad (1.29)$$

В двумерном СВП аналогично формируются субполосы $LL^{(j)}$, $LH^{(j)}$, $HL^{(j)}$, $HH^{(j)}$ полной размерности, что делает преобразование избыточным, но значительно более устойчивым к сдвигам. В контексте шумоподавления это важно, поскольку обеспечивает более стабильные оценки и меньшую склонность к артефактам [30, 61, 62, 65].

Дальнейшим развитием идеи субполосного разложения является пакетное вейвлет-преобразование (ПВП), позволяющее управлять процессом разделения спектра исходного сигнала/изображения на части более гибко, чем стандартная схема, где разлагается только ветвь аппроксимации. В вейвлет-пакетном подходе допускается последующее разложение не только аппроксимаций, но и деталей, что приводит к формированию полного двоичного дерева субполос и, следовательно, к более тонкому частотному разбиению (ценой возрастания вычислительной сложности и потенциальной избыточности коэффициентов). В дискретной формулировке потомки узла дерева задаются тем же оператором банка фильтров [35, 59]:

$$c_{j+1}^{(2p)}[n] = \sum_k h[k] c_j^{(p)}[2n-k], \quad c_{j+1}^{(2p+1)}[n] = \sum_k g[k] c_j^{(p)}[2n-k], \quad (1.30)$$

где $c_j^{(p)}$ — коэффициенты субполосы на уровне j и индексе полосы p . Чтобы сократить избыточное число коэффициентов и получить представление, подходящее для дальнейшей обработки, вводится задача выбора «оптимального дерева» (вейвлет-пакетного базиса) по аддитивному критерию. В качестве одного из естественных критериев применяется энтропийный критерий концентрации энергии коэффициентов (например, энтропия Шеннона).

Механизм построения вейвлет-пакетов можно описать рекурсивно, начиная со «масштабирующего пакета» $\omega_0(x) = \varphi(x)$: дальнейшие пакеты формируются последовательным разделением полосы частот одной и той же парой фильтров:

$$\omega_{2n}(x) = \sqrt{2} \sum_k h[k] \omega_n(2x - k), \quad \omega_{2n+1}(x) = \sqrt{2} \sum_k g[k] \omega_n(2x - k). \quad (1.31)$$

Стандартный материнский вейвлет $\psi(x)$ является частным элементом этой иерархии (как правило, $\omega_1(x)$). В двумерном случае аналогичные принципы применяются к субполосам вейвлет-коэффициентов (включая *LH*, *HL*, *HH* и их потомков). Это формирует разветвленное дерево ориентированно-частотных компонент, предоставляющее более широкие возможности для анализа и обработки благодаря более высокой степени адаптации к локальным особенностям текстуры [125].

Одним из важных направлений развития дискретного вейвлет-преобразования является **комплексное вейвлет-преобразование с двойным деревом** (КВП-ДД). Данный подход предназначен для ослабления ограничений классического ДВП, прежде всего его чувствительности к малым сдвигам сигнала (изображения) и ограниченной ориентационной селективности в двумерном случае.

Идея КВП-ДД состоит в том, что анализ выполняется не одним, а **двумя согласованными банками фильтров**, формирующими два параллельных дерева разложения. Если $a_j^{(a)}[n]$ и $a_j^{(b)}[n]$ обозначают коэффициенты аппроксимации на уровне j в первом и втором деревьях соответственно, то коэффициенты следующего уровня вычисляются по стандартной схеме фильтрации и прореживания:

$$\begin{aligned} a_{j+1}^{(a)}[k] &= \sum_n h_0^{(a)}[n - 2k] a_j^{(a)}[n], & d_{j+1}^{(a)}[k] &= \sum_n h_1^{(a)}[n - 2k] a_j^{(a)}[n], \\ a_{j+1}^{(b)}[k] &= \sum_n h_0^{(b)}[n - 2k] a_j^{(b)}[n], & d_{j+1}^{(b)}[k] &= \sum_n h_1^{(b)}[n - 2k] a_j^{(b)}[n], \end{aligned} \quad (1.32)$$

Комплексное представление формируется объединением выходов двух деревьев. Детализирующие коэффициенты записываются в виде:

$$d_{j+1}^{(c)}[k] = d_{j+1}^{(a)}[k] + i d_{j+1}^{(b)}[k], \quad (1.33)$$

где действительная и мнимая части соответствуют коэффициентам, полученным в двух параллельных ветвях разложения. Аналогично может быть введён комплексный коэффициент аппроксимации:

$$a_{j+1}^{(c)}[k] = a_{j+1}^{(a)}[k] + ia_{j+1}^{(b)}[k], \quad (1.34)$$

С функциональной точки зрения КВП-ДД можно интерпретировать через две взаимосвязанные вейвлет-функции $\psi_a(t)$ и $\psi_b(t)$, образующие комплексный вейвлет:

$$\psi_c(t) = \psi_a(t) + i\psi_b(t) \quad (1.35)$$

При согласованном выборе фильтров функция $\psi_b(t)$ рассматривается как приближённо квадратурная по отношению к $\psi_a(t)$, вследствие чего комплексный вейвлет обеспечивает более устойчивое представление локальных особенностей сигнала. Благодаря этому КВП-ДД обладает приближённой инвариантностью к сдвигу, то есть малые смещения сигнала приводят к существенно меньшим изменениям коэффициентов по сравнению со стандартным ДВП.

В двумерном случае КВП-ДД строится последовательным применением одномерных банков фильтров по строкам и столбцам изображения. В результате формируется набор аппроксимирующих и детализирующих субполос, обладающих более выраженной ориентационной селективностью, чем в классическом ДВП. Это особенно важно при анализе границ, линейных объектов, текстур и других анизотропных структур изображения.

1.3.3 Выбор типа вейвлета

При выборе вейвлет-базиса для подавления шума в изображениях необходимо учитывать как классические свойства вейвлетов, включая регулярность (гладкость), число нулевых моментов и компактность носителя, так и особенности обрабатываемого изображения. К числу таких особенностей относятся отсутствие инвариантности к сдвигам у ДВП, а также необходимость сохранения информативных деталей, в частности точечных рассеивателей, чётких границ и линейных объектов [34, 38, 54, 66–71, 74].

В общем случае вейвлет-базис выбирается таким образом, чтобы коэффициенты, соответствующие значимым особенностям изображения, формировали максимально разреженное представление и одновременно обеспечивали эффективное подавление шума за счёт их обработки без существенных артефактов реконструкции [30–34, 56–65].

Формально одним из ключевых свойств вейвлета является число нулевых моментов p , определяемое условием $\int_{-\infty}^{\infty} t^m \psi(t) dt = 0$, $m = 0, 1, \dots, p - 1$. В дискретном случае это условие записывается как $\sum_{l=0}^{A-1} l^m \psi_{j,k}[l] = 0$, где A обозначает число отсчетов, а $\psi_{j,k}[l]$ представляет собой вейвлет-функцию на масштабе j и сдвиге k . Практический смысл данного свойства заключается в том, что при увеличении p вейвлет-коэффициенты, соответствующие гладким участкам изображения, стремятся к нулю. Это обеспечивает разреженное представление и повышает эффективность фильтрации в однородных областях. Однако рост числа нулевых моментов обычно сопровождается увеличением длины фильтра (расширением носителя вейвлета), что ухудшает пространственную локализацию и может приводить к размыванию тонких деталей и усилению граничных эффектов. Поэтому при выборе вейвлета для фильтрации изображений важным критерием является не максимальное значение p само по себе, а оптимальное соотношение между числом нулевых моментов, регулярностью вейвлета и его пространственной локализацией [29, 34].

Регулярность (гладкость) вейвлета, количественно оцениваемая показателем Гельдера, влияет на устойчивость реконструкции и склонность метода к возникновению артефактов звона вблизи контрастных границ. Для изображений с большим числом границ более регулярные и симметричные фильтры обычно дают меньше артефактов после обнуления части коэффициентов. Компактность носителя (короткая импульсная характеристика фильтра) улучшает пространственную локализацию и способствует сохранению точечных рассеивателей и тонких линий, но может снижать эффективность подавления шума в однородных областях. Напротив, фильтры с расширенным носителем

обеспечивают более сильное сглаживание шума, но чаще приводят к размыванию мелких структур. В этой связи выбор семейства вейвлетов следует проводить с учетом фазовых свойств фильтров. Например, ортонормальные вейвлеты Добеши (dbN) обеспечивают высокую степень разреженности представления и компактный носитель, однако обладают асимметрией и могут вызывать фазовые искажения на границах объектов. Вейвлеты Symlet (symN) близки к вейвлетам Добеши по эффективности компактификации энергии, но обладают большей симметрией и поэтому чаще предпочтительны при обработке изображений. Вейвлеты Coiflet (coifN) обеспечивают повышенную регулярность при сохранении компактной поддержки, что полезно для подавления шума в гладких областях с контролем артефактов. Биортогональные вейвлеты (biorN.N) характеризуются линейно-фазовыми фильтрами и симметрией, благодаря чему пороговая обработка приводит к меньшему числу ложных осцилляций и более точному воспроизведению контуров. На практике для задач подавления шума, особенно когда критичны качество границ и отсутствие артефактов, биортогональные или симметричные базисы часто оказываются более предпочтительным выбором по сравнению с ортонормальными вейвлетами.

Спекл-шум имеет преимущественно мультипликативный характер. При этом требования к вейвлету фактически усиливаются: важно, чтобы он эффективно разделял структурные особенности (границы, линии, текстуры) и шумовую компоненту, а также не вызывал появления ложных границ после обратного преобразования [67–71, 74–75].

Дополнительно к выбору базиса принципиальное значение имеет алгоритм вейвлет-преобразования. Например, для PCA-изображений, где сохранение локальных экстремумов критично (например, точечных рассеивателей), предпочтительными часто оказываются варианты, инвариантные к сдвигу: СВП обеспечивает более стабильное подавление шума ценой увеличения избыточности представления и вычислительной сложности (см. п. 1.3.2); комплексное вейвлет-преобразование с двойным деревом (КВП-ДД) дает приближенную инвариантность к сдвигу и повышенную ориентационную селективность, что

особенно полезно при обработке протяженных ориентированных объектов (дороги, границы полей, элементы городской застройки) [38, 71].

В прикладных задачах выбор вейвлета разумно трактовать как подбор компромисса с учетом структуры изображения. Если приоритетом является одновременное подавление спекл-шума в однородных областях и сохранение четких границ без ложных осцилляций (эффекта Гиббса), обычно целесообразны симметричные или биортогональные базисы в сочетании с инвариантным к сдвигу разложением, особенно при использовании логарифмического преобразования и адаптивной пороговой обработки [27, 34, 65–71, 74]. Если изображение содержит множество ориентированных линий и диагональных элементов, на практике часто предпочтительнее КВП-ДД. Если в данных присутствуют ярко выраженные точечные рассеиватели и высококонтрастные локальные цели, следует избегать чрезмерно длинных и излишне гладких фильтров, а также избыточной глубины декомпозиции, поскольку это повышает риск усреднения локальных максимумов яркости. В таких случаях оправдан выбор вейвлетов с более коротким носителем и консервативных правил пороговой обработки [29–32, 34]. Если же изображение преимущественно однородно (например, гладкие поверхности), можно использовать базисы с повышенной регулярностью и/или большим числом нулевых моментов, поскольку они улучшают разреженность представления гладких областей, но при этом необходимо контролировать размывание редких границ и радиометрические искажения [29, 34, 65].

Поскольку универсально оптимального вейвлета для всех изображений не существует, наиболее воспроизводимым и научно обоснованным подходом является формирование ограниченной библиотеки кандидатов (например, вейвлеты Symlet, Coiflet, биортогональные вейвлеты, вейвлеты Добеши, а также варианты ДВП, СВП и КВП-ДД) с последующим выбором по критериям качества, отражающим специфику изображений: степень подавления спекл-шума в однородных областях, сохранение границ и линейных структур (градиентные метрики и меры контрастности границ), структурное подобие и отсутствие

артефактов реконструкции, а также сохранение радиометрической точности (контроль смещения яркости и контраста). В результате выбор типа вейвлета и алгоритма вейвлет-преобразования следует рассматривать как единый проектный выбор, при котором свойства базиса (число нулевых моментов, регулярность, симметрия, компактность носителя) согласуются с моделью шума и требованиями к сохранению информативных особенностей изображений [61–67].

1.3.4 Выбор уровня вейвлет-декомпозиции

Выбор уровня (глубины) вейвлет-декомпозиции L при фильтрации шума на изображениях является не менее важным, чем выбор базиса, поскольку именно L определяет масштабное разделение компонент изображения: на каких пространственных масштабах подавляется шум и на каких сохраняются (или, напротив, искажаются) структурные особенности. Формально для двумерного изображения размера $M \times N$ максимальная глубина ортогональной декомпозиции ограничена величиной $L_{\max} = \log_2(\min(M, N))$, однако использование $L \approx L_{\max}$ не является оптимальным для подавления шума. При увеличении числа уровней декомпозиции аппроксимирующая компонента становится всё более гладкой, а содержащиеся в ней детали объектов теряют чёткость вследствие многократного усреднения [29, 33–34, 65–71].

На практике уровень L следует выбирать как компромисс между подавлением шума в однородных областях и сохранением структур на характерных для задачи масштабах. Интуитивно каждый следующий уровень вейвлет-декомпозиции удваивает характерный размер анализируемых деталей: приблизительно, на уровне j субполосы деталей чувствительны к структурам порядка 2^j пикселей, а аппроксимация A_L описывает компоненты крупнее примерно 2^j пикселей. Поэтому разумная постановка выбора L заключается в согласовании 2^L с «крупнейшим масштабом деталей, которые нельзя терять»: если требуется сохранить, например, дорожную сеть, тонкие границы полей, береговые линии или контуры застройки, то L не должен быть настолько большим, чтобы эти структуры целиком перешли в аппроксимацию и

подверглись сглаживанию при обработке. В то же время, если изображение содержит обширные однородные области (водные поверхности, ровные равнины, лед), увеличение L до умеренных значений может существенно улучшить подавление спекл-шума, поскольку большая доля шумовой энергии попадает в субполосы деталей, где она эффективно подавляется пороговой обработкой.

Более формальный подход к выбору глубины вейвлет-декомпозиции L основан на анализе распределения энергии сигнала и шума по масштабам. Для РСА-изображений критически важно обеспечить, чтобы выбранный уровень L не приводил к переходу существенной доли шумовой компоненты в низкочастотную аппроксимацию A_L , где она не подвергается пороговой обработке коэффициентов деталей и сохраняется в реконструированном изображении. Признаком избыточной глубины декомпозиции служит наличие после фильтрации крупномасштабных неоднородностей (остаточного шума в аппроксимации A_L) одновременно с потерей мелких структур и снижением локального контраста. Признаком недостаточной глубины, напротив, является слабое подавление спекл-шума в однородных областях при удовлетворительном сохранении деталей: метод не охватывает масштаб, на котором шумовая компонента визуально доминирует над полезной структурой изображения [65–71, 74].

Для изображений среднего разрешения разумно начинать с глубины $L=3\div 5$ (в зависимости от размера изображения и требуемой детализации), поскольку эти уровни обычно обеспечивают достаточное разделение масштабов спекл-шума и структурных особенностей без чрезмерного размытия. При наличии множества мелких объектов и точечных рассеивателей предпочтительна меньшая глубина ($L=2\div 4$), чтобы избежать подавления локальных максимумов яркости; при доминировании крупных однородных областей допустимо увеличение глубины до $L=4\div 6$. Если применяется СВП или КВП-ДД, повышение глубины декомпозиции обычно менее критично с точки зрения появления артефактов реконструкции, однако риск избыточного усреднения и радиометрических искажений сохраняется, поэтому глубину следует ограничивать требованиями к сохранению информативных деталей изображения [38, 61, 65–71, 74].

Наиболее воспроизводимая научно обоснованная процедура выбора глубины вейвлет-декомпозиции L состоит в её рассмотрении как гиперпараметра с последующим подбором по целевым критериям качества, отражающим особенности изображений:

- снижение дисперсии и коэффициента вариации в однородных областях при сохранении среднего уровня яркости;
- сохранение границ и линейных структур (по величине градиента или контурным индексам до и после фильтрации);
- отсутствие характерных артефактов (ложные границы, артефакты звона, неестественная гладкость);
- сохранение ярких точечных рассеивателей (по контрасту локальных максимумов и пиковой яркости).

На практике это реализуется перебором значений L в узком диапазоне (например, $2 \div 6$) при фиксированном вейвлет-базисе и правиле пороговой обработки (или совместным подбором). После вычисления метрик качества выбирается минимальное значение L , обеспечивающее требуемое подавление спекл-шума в однородных областях без статистически значимого ухудшения метрик, характеризующих сохранение границ и контраста. Такой принцип «минимально достаточной глубины» особенно полезен для PCA-изображений, поскольку позволяет избежать типичной ошибки избыточной обработки: сильного сглаживания, которое визуально снижает зернистость спекл-шума, но одновременно уменьшает информативность изображения за счёт потери мелких структур и искажения радиометрических характеристик [128–129, 131–141].

1.3.5 Пороговая обработка вейвлет-коэффициентов

При вейвлет-фильтрации зашумленных изображений широко применяются методы пороговой обработки вейвлет-коэффициентов [30–32, 56–65]. Их эффективность основывается на характерном для изображений свойстве: значимая структура (контуры, локальные особенности, направленные текстуры) проявляется в сравнительно небольшом количестве коэффициентов с высокой амплитудой, тогда как шум, особенно в аддитивной модели, распределяется более

равномерно и в большей степени сосредотачивается в области малых значений. Пусть $W_Y^{(j,d)}$ — коэффициенты вейвлет-преобразования наблюдаемого изображения Y на уровне j в субполосе d ($d \in \{LH, HL, HH\}$ для БВП) [29–34]. Пороговая обработка задается правилом:

$$\hat{W}^{(j,d)} = T_{t_{j,d}}(W_Y^{(j,d)}), \quad (1.36)$$

где T_t — функция пороговой обработки с порогом $t_{j,d}$, который может быть универсальным для всех коэффициентов или зависеть от уровня декомпозиции. Наиболее распространенными вариантами функции T_t являются жесткое и мягкое пороговое отсечение. При жестком отсечении малые по модулю коэффициенты обнуляются, а остальные остаются без изменений [30, 31]:

$$\hat{W}^{(j,d)} = \begin{cases} \hat{W}^{(j,d)}, & \text{если } (W_Y^{(j,d)}) \geq t_{j,d}, \\ 0, & \text{если } (W_Y^{(j,d)}) < t_{j,d}. \end{cases} \quad (1.37)$$

Такая функция сохраняет амплитуду крупных коэффициентов, однако из-за разрывности в точке $\pm t_{j,d}$ может вызывать артефакты звона после обратного преобразования и проявлять меньшую устойчивость вблизи порога, особенно когда полезный сигнал и шум перекрываются по амплитудам. Мягкая пороговая обработка устраняет разрывность, одновременно обнуляя коэффициенты ниже порога и уменьшая по модулю коэффициенты выше порога на величину $t_{j,d}$:

$$\hat{W}^{(j,d)} = \begin{cases} \text{sign}(\hat{W}^{(j,d)}) (|W_Y^{(j,d)}| - t_{j,d}), & \text{если } |W_Y^{(j,d)}| \geq t_{j,d}, \\ 0, & \text{если } |W_Y^{(j,d)}| < t_{j,d}. \end{cases} \quad (1.38)$$

На практике мягкое пороговое отсечение часто обеспечивает более гладкое восстановление и эффективнее подавляет шум. Однако оно вносит систематическое смещение: амплитуда значимых коэффициентов уменьшается, что может приводить к ослаблению мелких деталей и снижению локального контраста. Чтобы уменьшить этот эффект, применяются непрерывные функции сжатия с насыщением (промежуточные пороговые правила), которые сохраняют непрерывность в окрестности порога и уменьшают смещение для коэффициентов

большой амплитуды, одновременно обеспечивая эффективное подавление шумовых компонент [56–60, 65].

Ключевым фактором качества является выбор порога $t_{j,d}$. В типичной постановке предполагается аддитивный белый гауссов шум:

$$Y = X + n, \quad n \sim N(0, \sigma^2), \quad (1.39)$$

и тогда в ортонормальном вейвлет-базисе шум в коэффициентах остается (приближенно) гауссовым с той же дисперсией, что позволяет оценивать σ по высокочастотной субполосе первого уровня вейвлет-декомпозиции [58, 62]. Робастная оценка через медиану абсолютных отклонений для диагональной субполосы первого уровня:

$$\hat{\sigma} = \frac{\text{median}(|W_Y^{(j, HH_1)}|)}{0.6741}, \quad (1.40)$$

устойчива к выбросам и к присутствию границ объектов. При наличии $\hat{\sigma}$ часто применяют «универсальный» порог Донохо – Джонстона (VisuShrink):

$$t = \hat{\sigma} \sqrt{2 \ln A}, \quad (1.41)$$

где A — число обрабатываемых коэффициентов. Универсальный порог прост в реализации, однако при больших A часто приводит к сильному сглаживанию изображения. Поэтому на практике широко применяются адаптивные методы выбора порогов по уровням декомпозиции и субполосам.

Метод на основе несмещённой оценки риска Штейна (Stein's Unbiased Risk Estimate, SURE) определяет порог $t_{j,d}$ для каждого уровня декомпозиции и каждой субполосы путём минимизации оценки среднеквадратичной ошибки реконструкции. Это позволяет адаптировать пороговую обработку к локальной статистике коэффициентов и, как правило, обеспечивает лучшее сохранение деталей при сопоставимом уровне подавления шума [65].

Байесовские методы выбора порога, в частности BayesShrink, используют статистическое моделирование распределения вейвлет-коэффициентов полезного сигнала и шума в каждой субполосе. Оптимальный порог $t_{j,d}$ определяется из условия минимизации апостериорной среднеквадратичной ошибки и зависит от

масштаба и ориентации субполосы. Такой подход особенно эффективен в случаях, когда энергия сигнала распределена по субполосам вейвлет-преобразования неравномерно [57–60].

Для практической обработки изображений обычно предпочтительны пороги, адаптированные к каждой субполосе, поскольку дисперсия и характер хвостов распределений коэффициентов заметно изменяются в зависимости от масштаба и ориентации. Кроме того, целесообразно учитывать межуровневые корреляции коэффициентов, то есть связи типа «родитель–дети», поскольку значимые структурные особенности часто проявляются согласованно на соседних уровнях вейвлет-декомпозиции. Если шум имеет неаддитивную природу, например, в случае мультипликативного спекл-шума в PCA-изображениях, то прямое применение рассмотренных правил пороговой обработки оказывается некорректным. В такой ситуации обычно применяются логарифмирование (гомоморфная обработка), после чего выполняются пороговая обработка коэффициентов вейвлет-преобразования и обратное преобразование к исходному представлению [20, 24, 70–71].

Таким образом, пороговая обработка вейвлет-коэффициентов остаётся вычислительно эффективным и теоретически обоснованным методом подавления шума. Наилучшие результаты достигаются при согласованном выборе робастной оценки параметров шума, соответствующей его статистической модели, а также функции и схемы пороговой обработки, адаптированных к конкретной субполосе. Это обеспечивает рациональный баланс между уровнем шумоподавления и сохранением информативных деталей изображения [30–32, 56–71, 74].

1.4 Статистическое моделирование методов фильтрации спекл-шума

1.4.1 Статистическое моделирование

Эффективность известных методов фильтрации, а также методов, разрабатываемых в диссертации, оценивалась с помощью вычислительных экспериментов, выполненных в среде программирования Python [146]. Экспериментальная база включала два категории изображений:

Категория 1 — реальные PCA-изображения, полученные из открытых каталогов данных компаний ICEYE (Финляндия), Synspecive (Япония) и Capella Space (США). Данная категория включала как однородные (водные поверхности, ровная местность), так и неоднородные PCA-изображения (городская застройка, прибрежные зоны), что позволило оценить адаптивность алгоритмов к различным типам текстур и структурных особенностей.

Категория 2 — стандартные эталонные неискажённые полутонные изображения размером 512×512 пикселей из баз данных TAMPERE17 [149] и USC-SIPi [150], широко применяемые для объективной оценки эффективности алгоритмов обработки изображений и охватывающие изображения с различной степенью текстурной сложности. В рамках экспериментальных исследований указанные изображения подвергаются зашумлению с целью формирования пар «чистое изображение – зашумлённое изображение», используемых для обучения и проверки эффективности алгоритмов.

Моделирование спекл-шума осуществлялось с помощью генераторов случайных чисел, реализованных на языке Python с использованием библиотек NumPy и SciPy [142-143]. Основное внимание уделено гамма-распределению с плотностью вероятности:

$$f(Z) = \begin{cases} \frac{L^L Z^{L-1} e^{-LZ}}{\Gamma(L)}, & Z > 0 \\ 0, & Z \leq 0 \end{cases}, \quad (1.42)$$

где $E[Z] = 1$ и дисперсия шума $Var[Z] = \frac{1}{L}$, что соответствует физической модели спекл-шума в PCA-изображениях. Значение дисперсии шума изменяется в ходе эксперимента для оценки устойчивости алгоритмов при различных уровнях зашумлённости.

Исследуемые методы обработки изображений были разделены на три основные группы: локальные пространственные фильтры, методы вейвлет-фильтрации и нейросетевые методы глубокого обучения.

К локальным пространственным фильтрам были отнесены медианный фильтр, фильтр Винера, а также фильтры Фроста и Ли.

Группа методов вейвлет-фильтрации включала методы пороговой обработки вейвлет-коэффициентов, в частности правила жёсткой (hard thresholding) и мягкой (soft thresholding) пороговой обработки, а также методы VisuShrink и BayesShrink.

К методам глубокого обучения были отнесены DnCNN и архитектура U-Net. Обучение данных моделей осуществлялось на 50 синтетически сформированных парах изображений с применением функции потерь, основанной на комбинации СКО и градиентной составляющей.

1.4.2 Система критериев оценки качества изображений

Для объективной количественной оценки эффективности восстановления применяется комплексный набор метрик, охватывающий как глобальные, так и локальные аспекты качества восстановленных изображений [85–89]. В качестве основных критериев используются среднеквадратичная ошибка (СКО), пиковое отношение сигнал-шум (ПОСШ), индекс структурного сходства (SSIM — Structural Similarity Index Measure) и многомасштабный индекс структурного сходства (MS-SSIM — Multi-Scale Structural Similarity Index Measure) [85–87]. Для количественной оценки степени проявления артефактов, возникающих в процессе обработки, дополнительно используется метрика GMSD (Gradient Magnitude Similarity Deviation) [87].

Для изображений категории 2 указанные критерии вычисляются относительно эталонных изображений. Для изображений категории 1 оценка эффективности фильтрации проводится преимущественно на основе визуального анализа результатов обработки.

СКО определяется следующим образом:

$$CKO(X, \hat{X}) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (X_{i,j} - \hat{X}_{i,j})^2, \quad (1.43)$$

где M , N — размеры изображений в пикселях; $X_{i,j}$, $\hat{X}_{i,j}$ — значения интенсивности пикселя оригинального изображения и его оценка в позиции (i, j) .

СКО непосредственно характеризует энергетическую близость к эталону, чувствительна к крупным локальным ошибкам, однако может быть недостаточно чувствительной к структурным и текстурным искажениям [85–87].

ПОСШ определяется как:

$$ПОСШ(X, \hat{X}) = 10 \log_{10} \left(\frac{(\max \{ \hat{X}_{i,j} \})^2}{\sum_{i=1}^m \sum_{j=1}^n (X_{i,j} - \hat{X}_{i,j})^2} \right) = 20 \log \frac{(\max \{ \hat{X}_{i,j} \})}{СКО}. \quad (1.44)$$

ПОСШ измеряется в децибелах (дБ), удобен для сравнений и визуализации зависимостей от уровня шума, но также не отражает полноценно структуру изображения [85–87].

Метрика SSIM оценивает структурное сходство, учитывая локальные средние, дисперсии и корреляцию:

$$SSIM(x, \hat{x}) = \frac{(2\mu_x \mu_{\hat{x}} + C_1)(2\sigma_{x\hat{x}} + C_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + C_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + C_2)}, \quad (1.45)$$

где μ_x — среднее значение в окне x оригинального изображения; $\mu_{\hat{x}}$ — среднее значение в окне \hat{x} оценки оригинала; σ_x^2 — дисперсия в окне x ; $\sigma_{\hat{x}}^2$ — дисперсия в окне \hat{x} ; $\sigma_{x\hat{x}}$ — ковариация окон x и \hat{x} ; константы $C_1 = (k_1 L)^2$ и $C_2 = (k_2 L)^2$, L — динамический диапазон пикселей; $k_1 = 0,01$, $k_2 = 0,03$ — экспериментально определенные константы.

Глобальный индекс SSIM для изображений X и \hat{X} рассчитывается как среднее арифметическое локальных оценок по формуле:

$$SSIM(X, \hat{X}) = \frac{1}{K} \sum_K SSIM(x, \hat{x}). \quad (1.46)$$

SSIM особенно важна в задаче спекл-фильтрации, так как позволяет отслеживать компромисс между подавлением зернистости и сохранением границ/структур.

Для преодоления ограничения метрики SSIM, связанного с оценкой структурного сходства только на одном масштабе, используется индекс MS-SSIM [84]. Основная идея данного подхода заключается в сравнении оригинального и обработанного изображений на разных пространственных масштабах.

При вычислении индекса MS-SSIM изображение последовательно разлагается на несколько масштабных уровней. На каждом уровне вычисляется значение SSIM. Итоговый индекс определяется следующим выражением:

$$MS-SSIM(X, \hat{X}) = \prod_{l=0}^L \omega_l \cdot SSIM_l^{a_l}(X, \hat{X}), \quad (1.47)$$

где L — число масштабов; $SSIM_l^{a_l}(X, \hat{X})$ — значение SSIM на l -ом масштабе; ω_l — вес, используемый для агрегирования; a_l — экспоненты, определяющие вклад каждого масштаба.

Метрика отклонения подобия величины градиента (GMSD — Gradient Magnitude Similarity Deviation) относится к полнореференсным показателям качества изображений и предназначена для оценки искажений на основе анализа градиентной структуры [87]. В её основе лежит предположение о том, что наиболее значимые визуальные искажения проявляются в изменениях яркостных переходов, соответствующих границам объектов и мелкомасштабным деталям изображения.

Для каждого пикселя вычисляется индекс сходства градиентов:

$$GMS(i, j) = \frac{2GM_X(i, j) \cdot 2GM_{\hat{X}}(i, j) + T}{GM_X(i, j)^2 \cdot GM_{\hat{X}}(i, j)^2 + T}, \quad (1.48)$$

где $GM_X(i, j)$ и $GM_{\hat{X}}(i, j)$ — градиентные величины оригинального изображения и его оценки в точке (i, j) , T — малая положительная константа для численной устойчивости. Итоговое значение GMSD определяется как стандартное отклонение значений GMS по изображению:

$$GMSD(X, \hat{X}) = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (GMS(i, j) - \overline{GMS})^2}, \quad (1.49)$$

где M, N — размеры изображений в пикселях, \overline{GMS} — среднее арифметическое всех значений GMS. В отличие от метрик, основанных на усреднении ошибки, GMSD чувствительна к локальным искажениям структуры изображения. Это обуславливает её преимущество при выявлении артефактов, возникающих вблизи границ объектов, в том числе артефактов звона (ringing artifacts), характерных для

методов обработки в вейвлет-областях. За счёт анализа вариаций градиента метрика эффективно фиксирует паразитные осцилляции и искажения высокочастотных компонент, что делает её целесообразной для применения при оценке количества артефактов, вносимых пороговой обработкой вейвлет-коэффициентов.

В задаче фильтрации и обработки зашумленных изображений эффективность восстановления определяется минимизацией СКО и GMSD, максимизацией ПОСШ, SSIM, MS-SSIM, а также отсутствием визуально заметных артефактов, включая избыточное сглаживание, ступенчатость, ложные контуры и потерю мелких деталей.

1.4.3 Результаты статистического моделирования

В данном разделе представлены результаты исследования эффективности шумоподавления с использованием вейвлет-преобразования. Рассмотрено влияние основных факторов, определяющих результативность фильтрации, включая тип вейвлета, метод и правило пороговой обработки, схему вейвлет-декомпозиции, а также класс обрабатываемого изображения.

Экспериментальные результаты представлены в таблицах и на рисунках. В табл. 1.1 и на рис. 1.2 приведены результаты исследования влияния выбора типа вейвлета на эффективность фильтрации. В табл. 1.2 и на рис. 1.3 представлены результаты исследования влияния метода пороговой обработки на эффективность шумоподавления. В табл. 1.3 и на рис. 1.4 показано влияние правила пороговой обработки на эффективность шумоподавления. В табл. 1.4 и на рис. 1.5 приведены результаты исследования влияния алгоритма вейвлет-преобразования на эффективность шумоподавления. На рис. 1.6 и 1.7 представлены результаты исследования влияния текстурности изображений на метрики качества при обработке вейвлет-коэффициентов различными методами.

На основе результатов моделирования устанавливаются следующие общие выводы.

1. В рамках проведённых экспериментов при выбранных параметрах тип вейвлета оказал сравнительно слабое влияние на итоговые значения метрик СКО, ПОСШ и SSIM при прочих равных условиях. Исключение составляет вейвлет

Хаара, продемонстрировавший заметно худшие результаты. Остальные вейвлеты показали близкие значения рассматриваемых метрик. Среди них вейвлет Coif5 обеспечил наибольшее значение ПОСШ, тогда как Bior4.4 продемонстрировал наибольшее значение SSIM.

Полученный результат согласуется с теоретическими представлениями. Койфлеты обладают сбалансированными моментами и хорошими аппроксимирующими свойствами, что способствует эффективному подавлению шума в однородных областях без существенного искажения амплитудных характеристик сигнала, обеспечивая высокие значения отношения сигнал-шум. Биортогональные вейвлеты, в частности Bior4.4, благодаря симметрии базисных функций и их гладкости позволяют уменьшить артефакты вблизи границ объектов и лучше сохранять пространственные корреляции между соседними пикселями, что особенно важно для метрики SSIM, характеризующей структурное сходство изображений.

2. Правило пороговой обработки существенно влияет на итоговые значения метрик СКО, ПОСШ и SSIM: наилучшие значения в проведённом эксперименте обеспечивает жёсткая пороговая обработка. Для обработки изображений жёсткий порог позволяет минимизировать потери полезной информации, что подтверждается лучшими численными показателями. Мягкая пороговая обработка, как правило, приводит к более гладкому результату, однако сопровождается более высоким риском сглаживания мелких деталей.

3. Метод пороговой обработки оказывает существенное влияние на итоговые значения метрик СКО, ПОСШ и SSIM. Метод VisuShrink продемонстрировал заметно худшие результаты в общей совокупности экспериментов. Наиболее высокие значения ПОСШ и SSIM были получены при использовании методов BayesShrink и SureShrink.

Как и в случае с другими исследуемыми факторами, эффективность методов пороговой обработки зависит от уровня текстурности изображения. В частности, для однородных изображений (рис. 1.6, а и рис 1.7, а) метод VisuShrink в ряде случаев обеспечивает наилучшие результаты шумоподавления.

4. Алгоритм вейвлет-преобразования существенно влияет на итоговые значения СКО, ПОСШ и SSIM. В проведённых экспериментах наилучшие показатели качества на всех уровнях шума обеспечила алгоритм КВП-ДД. Классический алгоритм ДВП, напротив, продемонстрировало наихудшие результаты.

Таблица 1.1 – Зависимость СКО, ПОСШ и SSIM от типа вейвлета

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение				
		haar	db7	sym4	coif5	bior4.4
СКО ($\times 10^{-3}$)						
0,02	6,93	3,67	3,09	2,99	2,79	2,88
0,04	11,98	5,19	4,12	4,00	3,76	3,89
0,06	17,71	6,53	5,01	4,90	4,62	4,73
0,08	21,72	7,41	5,75	5,62	5,31	5,43
0,10	26,06	8,22	6,38	6,24	5,89	6,10
ПОСШ						
0,02	21,59	24,35	25,12	25,25	25,55	25,40
0,04	19,21	22,85	23,85	23,98	24,25	24,11
0,06	17,52	21,85	23,02	23,13	23,35	23,25
0,08	16,63	21,31	22,42	22,51	22,75	22,65
0,10	15,84	20,85	21,95	22,05	22,31	22,15
SSIM						
0,02	0,58	0,59	0,64	0,66	0,67	0,68
0,04	0,45	0,52	0,59	0,60	0,61	0,63
0,06	0,37	0,48	0,55	0,56	0,57	0,58
0,08	0,31	0,46	0,52	0,53	0,54	0,55
0,10	0,28	0,44	0,51	0,52	0,53	0,54




Рисунок 1.2 – Зависимость ПОСШ и SSIM от типа вейвлета

Таблица 1.2 – Зависимость СКО, ПОСШ и SSIM от метода пороговой обработки

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		VisuShrink	SureShrink	BayesShrink
СКО ($\times 10^{-3}$)				
0,02	6,63	3,27	2,85	2,60
0,04	12,85	4,29	3,76	3,47
0,06	18,28	5,19	4,57	4,12
0,08	23,82	5,92	5,25	4,73
0,10	27,60	6,53	5,78	5,15
ПОСШ				
0,02	21,78	24,85	25,45	25,85
0,04	18,91	23,68	24,25	24,62
0,06	17,38	22,85	23,42	23,85
0,08	16,23	22,28	22,81	23,25
0,10	15,59	21,85	22,38	22,88
SSIM				
0,02	0,56	0,66	0,69	0,72
0,04	0,44	0,58	0,63	0,67
0,06	0,35	0,52	0,58	0,64
0,08	0,28	0,48	0,54	0,61
0,10	0,24	0,44	0,53	0,59

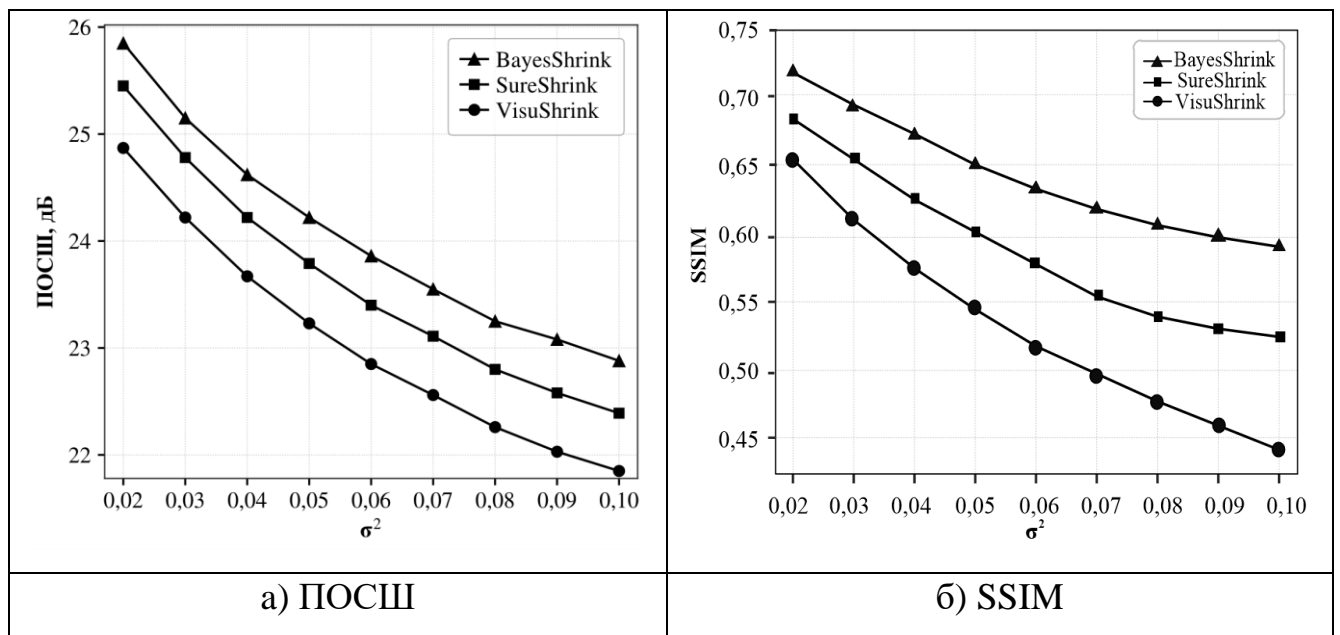


Рисунок 1.3 – Зависимость ПОСШ и SSIM от метода пороговой обработки

Таблица 1.3 – Зависимость СКО, ПОСШ и SSIM от правила пороговой обработки

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		Жесткая	Полумягкая	Мягкая
СКО ($\times 10^{-3}$)				
0,02	6,57	3,24	3,67	4,09
0,04	12,71	4,27	4,68	4,95
0,06	17,94	5,11	5,47	5,82
0,08	23,33	5,86	6,17	6,43
0,10	27,35	6,38	6,61	6,92
ПОСШ				
0,02	21,82	24,91	24,35	23,88
0,04	18,96	23,70	23,31	23,05
0,06	17,46	22,92	22,62	22,35
0,08	16,32	22,32	22,10	21,92
0,10	15,63	21,95	21,80	21,60
SSIM				
0,02	0,56	0.63	0.59	0.55
0,04	0,44	0.56	0.52	0.49
0,06	0,35	0.49	0.47	0.44
0,08	0,28	0.45	0.43	0.41
0,10	0,24	0.43	0.40	0.39

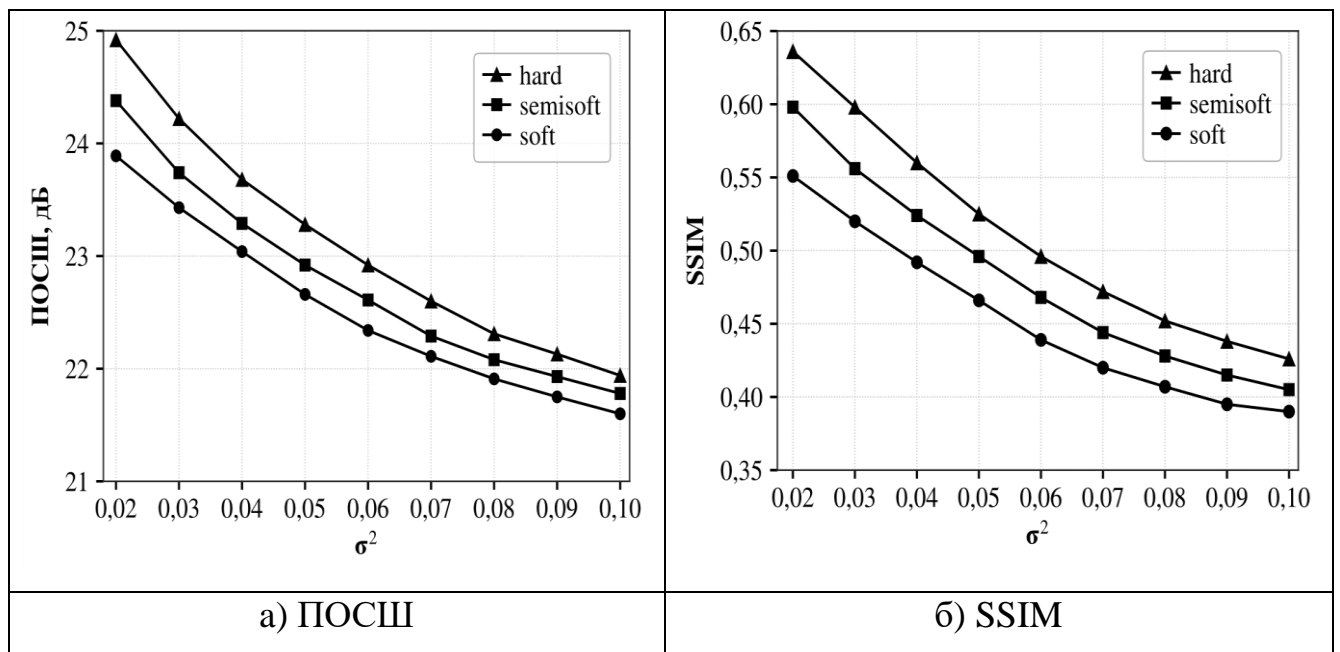


Рисунок 1.4 – Зависимость ПОСШ и SSIM от от метода пороговой обработки

Таблица 1.4 – Зависимость СКО, ПОСШ и SSIM от алгоритма вейвлет-преобразования

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		ДВП	СВП	КВП-ДД
СКО ($\times 10^{-3}$)				
0,02	5,94	3,27	2,85	2,57
0,04	10,18	4,37	3,63	3,39
0,06	14,09	5,19	4,32	4,03
0,08	16,36	5,75	4,88	4,62
0,10	21,28	6,14	5,25	4,95
ПОСШ				
0,02	22,26	24,85	25,45	25,90
0,04	19,92	23,62	24,41	24,72
0,06	18,51	22,85	23,65	23,95
0,08	17,86	22,41	23,12	23,35
0,10	16,72	22,12	22,82	23,05
SSIM				
0,02	0.59	0.62	0.66	0.68
0,04	0.47	0.56	0.61	0.64
0,06	0.38	0.51	0.58	0.61
0,08	0.32	0.48	0.55	0.59
0,10	0.28	0.45	0.54	0.57




Рисунок 1.5 – Зависимость ПОСШ и SSIM от алгоритма вейвлет-преобразования

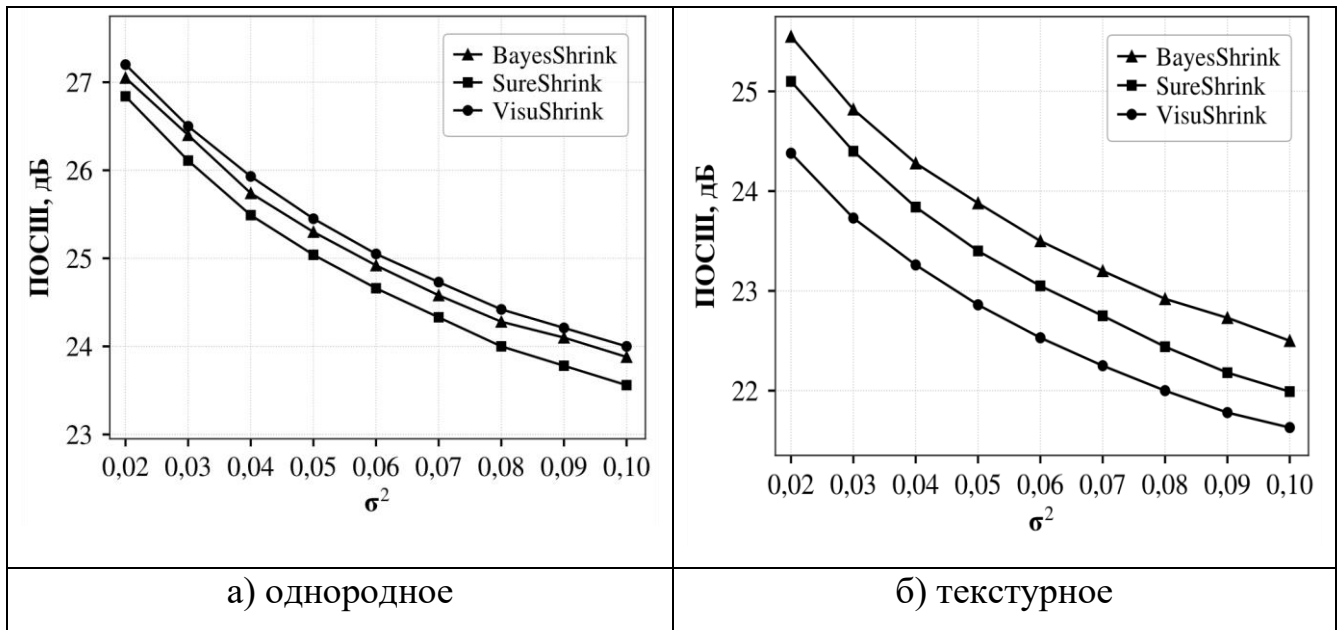


Рисунок 1.6 – Зависимость ПОСШ от метода пороговой обработки при обработке изображений с различным уровнем текстурированности

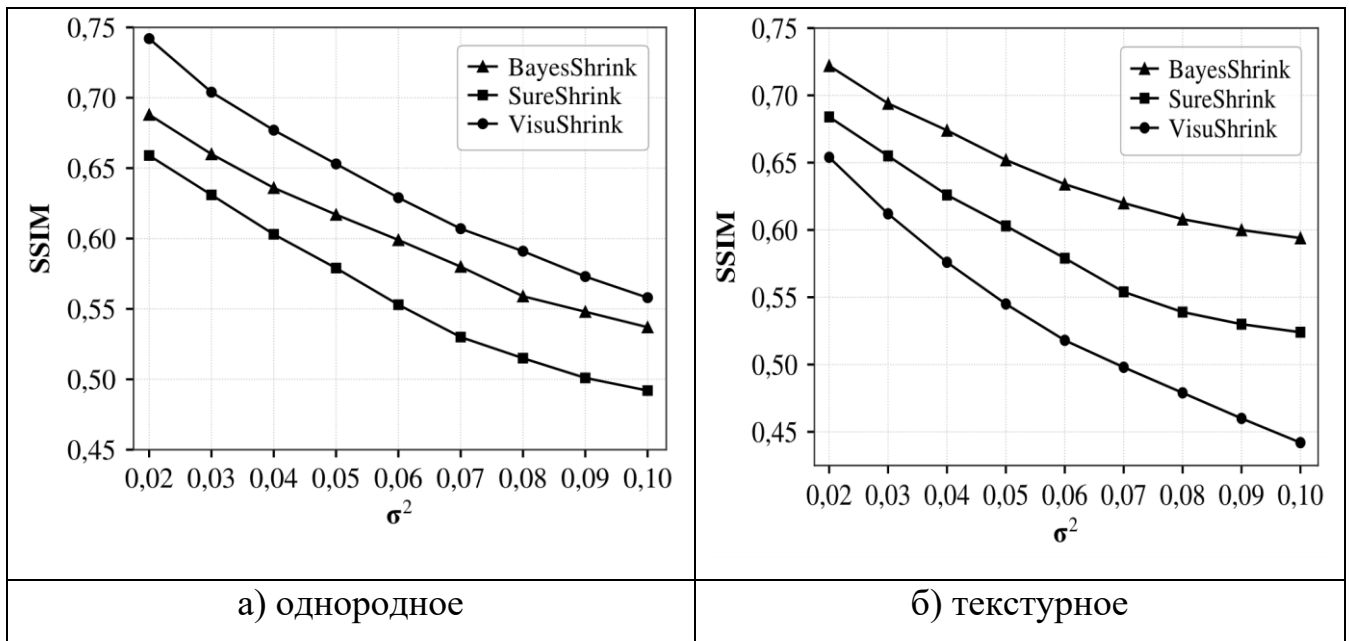


Рисунок 1.7 – Зависимость SSIM от метода пороговой обработки при обработке изображений с различным уровнем текстурированности

Целесообразно также определить место вейвлет-фильтрации среди методов пространственной фильтрации. Результаты сравнения приведены в табл. 1.5 и на рис. 1.8. Как видно из полученных данных, наилучшее подавление шума обеспечивают фильтр Винера, фильтр Ли и адаптивный метод пороговой обработки вейвлет-коэффициентов BayesShrink.

Таблица 1.5 – Результат сравнения различных методов фильтрации

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение						
		Медианный фильтр	Фильтр Фрост	Фильтр Винер	Фильтр Ли	Метод NLM	Visu Shrink	Bayes Shrink
ПОСШ								
0,02	22,2	23,3	25,0	26,2	26,1	25,6	24,3	26,4
0,04	19,6	21,6	23,3	24,8	24,7	24,3	23,2	24,9
0,06	17,8	20,4	22,3	23,6	23,5	23,3	22,2	23,5
0,08	16,7	19,5	21,7	22,9	22,7	22,4	21,6	22,8
0,10	15,9	18,9	21,3	22,3	22,1	21,9	21,2	22,2
SSIM								
0,02	0.59	0.62	0.65	0.70	0.69	0.72	0.61	0.71
0,04	0.47	0.54	0.58	0.63	0.62	0.62	0.56	0.64
0,06	0.38	0.49	0.53	0.58	0.57	0.56	0.51	0.59
0,08	0.32	0.45	0.50	0.54	0.53	0.52	0.48	0.54
0,10	0.28	0.42	0.47	0.50	0.50	0.48	0.45	0.51

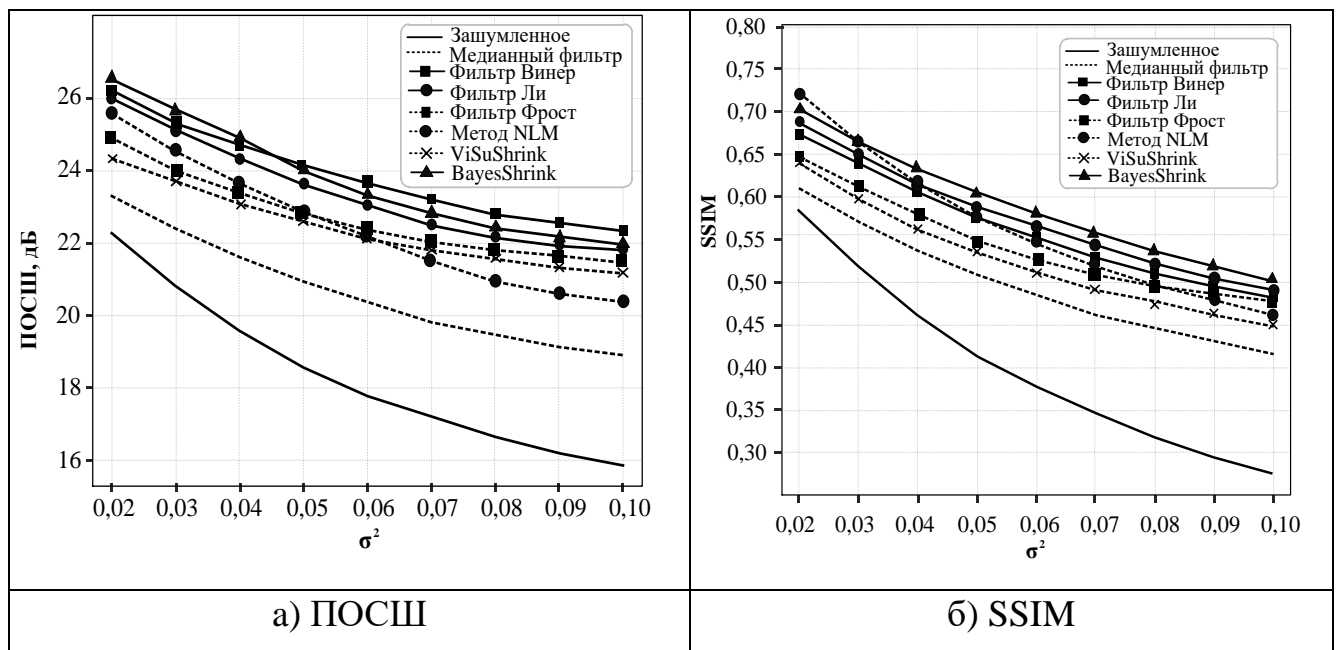


Рисунок 1.8 – Результат сравнения различных методов фильтрации

1.5 Постановка задачи

В настоящей работе рассматриваются зашумлённые изображения, имеющие кусочно-регулярную структуру в градациях серого цвета. К таким изображениям относятся, например, РСА-снимки сельскохозяйственных угодий, изображения городского ландшафта с регулярной застройкой, карты логистических маршрутов

и т.п. В разделе 1.3 показано, что вейвлет-преобразование является кратномасштабным преобразованием, когда каждая субполоса содержит образ исходного изображения в своем частотном диапазоне. Таким образом, будет наблюдаться корреляция между вейвлет-коэффициентами субполос, что доказано теоретически и используется при построении различных вейвлет-кодеков, например, SPIHT [115, 116]. При этом двумерная вейвлет-декомпозиция представляется в виде множества одномерных пространственно-ориентированных деревьев (ПОД), что используется в кодеках, а также в третьей главе данной работы, где приводится детальное описание процесса формирования ПОД. В результате как НЧК, соответствующие множеству вейвлет-коэффициентов аппроксимации, так и высокочастотные субполосы – детали – будут в том или ином виде представлять зашумленное обрабатываемое изображение на разных масштабах. В субполосах аппроксимации вейвлет-коэффициенты имеют значительную величину, поскольку именно сюда «перетекает» энергия сигнала в результате вейвлет-преобразования [27, 33]. А вейвлет-коэффициенты деталей, наоборот, имеют относительно низкую величину, близкую к нулю. Следовательно, спекл проявляется заметным образом именно в высокочастотных субполосах, тогда как в субполосах аппроксимации наблюдается высокое отношение сигнал-шум.

Если добавить вейвлет-коэффициенты аппроксимации после соответствующего масштабирования к каждой высокочастотной субполосе, то, принимая во внимание корреляцию субполос, произойдет заметное увеличение числа больших вейвлет-коэффициентов деталей, в то время как увеличение числа относительно малых по величине вейвлет-коэффициентов деталей останется практически незаметным. Тем не менее, общее число больших по величине вейвлет-коэффициентов возрастет, и, следовательно, увеличится отношение сигнал-шум. Если к такому массиву вейвлет-коэффициентов применить пороговую обработку для подавления остаточного спекла, то величина порога будет меньше по сравнению с величиной порога для исходного изображения. Это означает, что больше сохранится вейвлет-коэффициентов аппроксимации и,

таким образом, количество вносимых артефактов звона будет существенно ниже. При обратном вейвлет-преобразовании произойдет восстановление другого изображения, отличного от исходного, но, зная добавленные вейвлет-коэффициенты аппроксимации, достаточно восстановить «добавляемое изображение» (псевдо-изображение) и вычесть его из сформированной оценки оригинала.

Согласно [113], изображение может быть представлено следующим образом:

$$\hat{X} = \sum_{k=1}^M W^{-1} \{w_{Y_k}\}, \quad (1.50)$$

где M – число вейвлет-коэффициентов и $|w_{Y_k}| \geq |w_{Y_{k+1}}|, \forall k \in [1, \dots, M]$.

Данная идея подтверждается следующим образом. На рис. 1.8 представлены кривые спада упорядоченных по величине вейвлет-коэффициентов (трехуровневое БВП, вейвлет db7) неискаженного (цифра 1 на рис. 1.9) и зашумленного изображений (цифра 2, мультипликативный шум с единичным средним и дисперсией $\sigma^2 = 0.05$) соответственно.

Такое поведение вейвлет-коэффициентов является характерным для изображений с кусочно-регулярными структурами. Из рис. 1.9 видно, что из-за действия шума происходит отклонение кривой спада зашумленного изображения в окрестности точки начала координат, причем, чем больше дисперсия шума, тем больше отклонение. Тем не менее, число нулевых коэффициентов остается относительно большим. Из рис. 1.9 следует, что для достижения целей «хорошей» фильтрации необходимо получить похожую кривую спада (цифра 1), для чего требуется выставить порог τ_1 для второй кривой спада (цифра 2). Смыслом пороговой обработки становится получение новой кривой спада вейвлет-коэффициентов, близкой к кривой спада неискаженного изображения. Как видно из рис. 1.9, в результате пороговой обработки происходит обнуление относительно большой части вейвлет-коэффициентов, относящихся к

аппроксимации, что обуславливает появление артефактов звона и, частично, блочных артефактов.




Рисунок 1.9 – Кривые спада части вейвлет-коэффициентов неискаженного (1), зашумленного изображений (2) и модифицированного изображения (3)

Арифметическое добавление вейвлет-коэффициентов аппроксимации к вейвлет-коэффициентам деталей приводит к тому, что после нормализации модифицированной кривой спада вейвлет-коэффициентов новая кривая спада (цифра 3) принимает вид, похожий для вида кривой спада неискаженного изображения. Фактически получается, что кривая спада вейвлет-коэффициентов модифицированного изображения как бы сдвинута вверх на величину добавленных вейвлет-коэффициентов НЧК. Формально величина выставяемого порога τ_2 оказывается выше величины порога τ_1 , но, поскольку величина сдвига известна, то в этом случае не происходит подавление информативных вейвлет-коэффициентов. Следовательно, происходит меньшее добавление артефактов в обработанное изображение, что доказывает ранее высказанное обоснование.

Таким образом, принимая во внимание результаты обзора, целью исследований является теоретическое обоснование, разработка, экспериментальное исследование и практическая реализация алгоритмов анализа

и фильтрации изображений, искаженных мультипликативным шумом на основе усиления НЧК и использования вейвлет-преобразования и нейронных сетей.

Для достижения поставленной цели в диссертационной работе решаются следующие задачи.

1. Сравнительный анализ и классификация существующих методов и алгоритмов анализа, обработки и фильтрации изображений, искаженных мультипликативным шумом, в том числе с использованием вейвлет-преобразования и нейронных сетей.

2. Обоснование выделения НЧК зашумленного изображения и их добавления в высокочастотную область спектра для повышения эффективности алгоритмов анализа и обработки зашумленных изображений.

3. Разработка и исследование алгоритмов устранения мультипликативного шума на основе пороговой обработки вейвлет-коэффициентов с усилением НЧК в высокочастотных субполосах.

4. Разработка и исследование алгоритмов комбинированной вейвлет-фильтрации зашумленных изображений на основе их текстурного анализа.

5. Разработка и исследование алгоритмов фильтрации зашумленных изображений с использованием нейронных сетей на основе информации о пространственно-ориентированных деревьях (ПОД) вейвлет-преобразования.

1.6 Выводы по первой главе

В первой главе проведен обзор методов и алгоритмов анализа и фильтрации изображений, искаженных спекл-шумом.

1. Показано, что мультипликативный характер спекл-шума существенно ухудшает качество изображений, снижает их информативность и затрудняет последующую обработку.

2. Установлено, что традиционные методы пространственной и частотной фильтрации, а также современные нейросетевые подходы позволяют снизить уровень шума. Однако они не в полной мере обеспечивают требуемый баланс между эффективностью шумоподавления, сохранением границ, текстурных

особенностей и мелких деталей изображения, а также вычислительной сложностью обработки.

3. Обоснована целесообразность использования вейвлет-преобразования в качестве основы для модификации существующих и разработки новых алгоритмов фильтрации зашумленных изображений. Это обусловлено возможностью многомасштабного анализа изображения и разделения его информативных и шумовых компонентов.

4. Обоснована целесообразность выделения НЧК и их добавления в высокочастотную область спектра с целью повышения эффективности алгоритмов анализа и обработки зашумленных изображений.

В результате проведенного анализа обоснована постановка задач диссертационного исследования.

ГЛАВА 2. АЛГОРИТМЫ ВЕЙВЛЕТ-АНАЛИЗА И ОБРАБОТКИ ЗАШУМЛЕННЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ УСИЛЕНИЯ НИЗКОЧАСТОТНЫХ КОМПОНЕНТ

2.1 Модифицированный алгоритм пороговой обработки вейвлет-коэффициентов с усилением НЧК в высокочастотных субполосах

2.1.1 Алгоритм пороговой обработки вейвлет-коэффициентов

Из раздела 1.4 следует, что выбор правила пороговой обработки и величины порога играет существенную роль в процессе фильтрации зашумленного изображения. Существует много методов расчета порогового значения [30–32, 56–57]. В частности, можно рассчитывать глобальный порог для обработки всех коэффициентов деталей, так и отдельные пороги для каждой субполосы. Но в любом случае возможны ситуации, когда обнуление некоторых вейвлет-коэффициентов выражается в значительном сглаживании изображения и/или появлении артефактов (последнее проявляется как размытие краев объектов). Предугадать, какие коэффициенты, оказавшиеся ниже порога, не нужно обнулять, теоретически и практически очень сложно, и авторам неизвестны подобные решения. Очевидно, что причиной обнуления значимых вейвлет-коэффициентов является низкое отношение сигнал-шум в субполосах из-за действия шума. В связи с этим возникает задача повышения отношения сигнал-шум в высокочастотных субполосах за счёт усиления НЧК. Идея предлагаемого алгоритма вейвлет-фильтрации заключается в использовании для этой цели аппроксимации (НЧК), поскольку она практически не содержит искажений из-за действия шума. Для описания предлагаемого алгоритма ниже цитируются соответствующие фрагменты работ [130] и [131].

Для получения оценки изображения \hat{X} будем применять трехуровневое БВП (рис. 2.1) с использованием последующей пороговой обработки вейвлет-коэффициентов по т.н. «грубому» правилу. На рис. 2.1 буквами A , D , H и V с индексами обозначены массивы вейвлет-коэффициентов аппроксимации, диагональных, горизонтальных и вертикальных субполос соответственно. При

обработке вейвлет-коэффициентов по «грубому» правилу те коэффициенты, которые оказались ниже порога, обнуляются, а оставшиеся коэффициенты остаются без изменений. Отметим, что вейвлет-коэффициенты аппроксимации (сегмент A_3 в верхнем левом углу на рис. 2.1) не подвергаются пороговой обработке.




Рисунок 2.1 – Схема трехуровневого быстрого вейвлет-преобразования

Тогда модификация алгоритма пороговой вейвлет-фильтрации зашумленного изображения будет заключаться в усилении НЧК в высокочастотных субполосах вейвлет-преобразования путем использования аппроксимации, полученной из БВП более низкого уровня. Аппроксимация может использоваться для извлечения НЧК, соответствующих деталям. Это позволяет модифицировать детали БВП путем добавления извлеченных НЧК, что приводит к увеличению отношения сигнал-шум в субполосах деталей [130].

Основной принцип работы предложенного алгоритма иллюстрируется на рис. 2.2 и состоит из следующих шагов [131].

1. На первом шаге вначале выполняются одноуровневое и трёхуровневое БВП над искажённым изображением Y . В результате формируются соответствующие массивы вейвлет-коэффициентов. $[cA_1, cS_1]$ и $[cA_3, cS_n]$, где $cS_n = [cD_n, cV_n, cH_n]$ и $n = 1, 2, 3$.

2. Теперь необходимо получить псевдо-изображение по аппроксимирующим коэффициентам, для чего, например, восстанавливаем изображение Y^{A_1} из коэффициентов аппроксимации A_1 , применяя процедуру

обратного вейвлет-преобразования. При этом детализирующие коэффициенты берутся нулевыми.

3. На третьем шаге снова выполняется трехуровневое вейвлет-преобразование над “псевдо-изображением” Y^{A_1} . Формируются массивы вейвлет-коэффициентов $[cA_3^{A_1}]$ и $cS_n^{A_1} = [cH_n^{A_1}, cV_n^{A_1}, cD_n^{A_1}]$.

4. На четвертом шаге осуществляется суммирование детализирующих вейвлет-коэффициентов, полученных в результате трехуровневого двумерного вейвлет-преобразования на первом шаге, с детализирующими вейвлет-коэффициентами, полученными на третьем шаге. Математически эта операция выражается следующим образом: $c\bar{S}_n = cS_n + cS_n^{A_1}$.

5. Выполняется "грубая" пороговая обработка детализирующих вейвлет-коэффициентов, полученных на первом и четвертом этапах, в результате чего формируются новые массивы детализирующих вейвлет-коэффициентов: $c\bar{S}_n = [c\bar{H}_n, c\bar{V}_n, c\bar{D}_n]$ и $c\tilde{S}_n = [c\tilde{H}_n, c\tilde{V}_n, c\tilde{D}_n]$.

6. Сравниваются значения вейвлет-коэффициентов, полученных после "грубой" пороговой обработки на шаге 5. Если $c\bar{S}_n(i) = 0$ и $c\tilde{S}_n(i) \neq 0$, то принимаем $c\tilde{S}_n(i) = c\tilde{S}_n(i) - cS_n^{A_1}(i)$, $i = 1, \dots, m$, где m – количество элементов в cS_n . В противном случае, $c\tilde{S}_n(i) = c\bar{S}_n(i)$.

7. Оценка оригинала \hat{X} получается с помощью обратного вейвлет-преобразования, применяемого к новым массивам вейвлет-коэффициентов $[A_3, cS_n]$.

Вычислительная сложность алгоритма определяется операциями прямого и обратного вейвлет-преобразования, формирования псевдоизображения и поэлементного суммирования, что обеспечивает асимптотику $O(N^2)$ по времени и памяти.

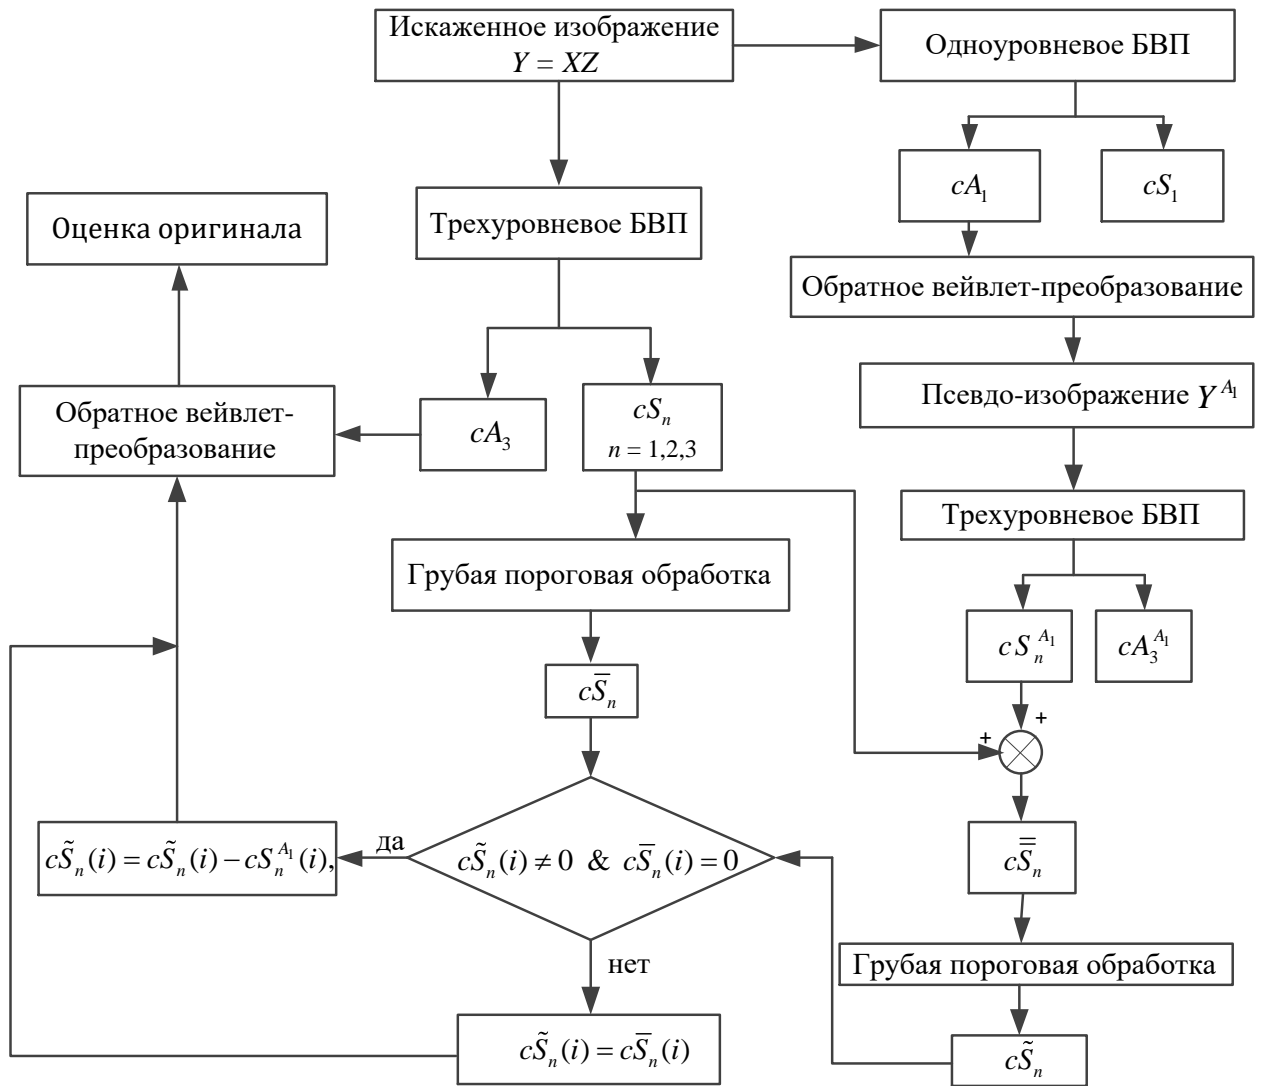


Рисунок 2.2 – Основной принцип предлагаемого алгоритма

2.1.2 Результаты моделирования

Экспериментальная оценка эффективности предложенного алгоритма выполнена в программной среде Python на наборе из десяти эталонных изображений в градациях серого, с глубиной цвета 8 бит на пиксель и размером 512×512 пикселей, взятых из баз данных TAMPERE17 и USC-SIPI. Величина глобального порога для «грубого» правила вычислялась на основе дисперсии массива вейвлет-коэффициентов субполосы H_1 . Для сравнения в табл. 2.1 помещены также данные по ПОСШ, SSIM, MS-SSIM и GMSD для метода вейвлет-фильтрации VisuShrink на основе правила «грубой» пороговой обработки. В ходе исследования предложенного алгоритма использовались различные типы вейвлетов; в табл. 2.1 отражены результаты, полученные при использовании

«классического» для шумоподавления вейвлет-базиса db7 из семейства вейвлетов Добеши. Для наглядности полученные данные статистической обработки для ПОСШ и SSIM показаны также в виде соответствующих зависимостей на рис. 2.3 и рис. 2.4 соответственно. На рис. 2.5 показаны результаты обработки эталонного изображения, содержащего четыре объекта с произвольными формами и яркостями на темном фоне. На рис. 2.5, а приведено неискаженное изображение, на рис. 2.5, б представлено зашумленное изображение с дисперсией шума 0,05, а рис. 2.5, в и 2.5, г отражают результаты обработки зашумленного тестового изображения методом VisuShrink и предложенным алгоритмом соответственно.

Как видно из рис. 2.3 и рис. 2.4, а также табл. 2.1, предложенный алгоритм демонстрирует лучшие значения метрик по сравнению с методом пороговой обработкой вейвлет-коэффициентов VisuShrink при относительно небольших значениях дисперсии шума по критериям ПОСШ, SSIM, MS-SSIM и GMSD. Тем не менее, оба метода показывают примерно одинаковое увеличение ПОСШ при увеличении дисперсии шума до таких значений, когда практически объекты на изображении становятся неразличимы визуально. Данный факт можно объяснить тем, что при относительно больших шумах добавление НЧК в высокочастотных субполосах вносит дополнительные искажения вместо повышения отношения сигнал-шум. Таким образом, предложенный алгоритм следует применять в тех случаях, когда удаление шумов не должно приводить к появлению новых артефактов. Данное свойство предложенного алгоритма иллюстрируется рис. 2.5, из которого видно, что в данном конкретном примере метод вейвлет-фильтрации VisuShrink вносит свои артефакты, причем они появляются не только по краям объектов, но также и в изображениях самих объектов (рис. 2.5, в). Как видно из рис. 2.5, г, количество артефактов, вносимое предложенным алгоритмом, значительно ниже. Это подтверждается и численными значениями метрики GMSD, которые меньше у предложенного алгоритма (табл. 2.1). Необходимо также отметить, что предложенный алгоритм вейвлет-фильтрации с усилением НЧК в высокочастотных субполосах практически восстанавливает оригинальное распределение яркостей

объектов и фона (рис. 2.5, а и рис. 2.5, г), в то время как метод VisuShrink может установить ошибочную яркость объектов и фона (рис. 2.5, в).

Таблица 2.1 – Результаты экспериментов

σ^2	Зашумлённое изображение				Восстановленное изображение							
	ПОСШ (дБ)	SSIM	MS-SSIM	GMSD	ПОСШ (дБ)		SSIM		MS-SSIM		GMSD	
					(*)	(**)	(*)	(**)	(*)	(**)	(*)	(**)
0,02	22,2	0,60	0,84	0,043	24,8	25,5	0,65	0,71	0,92	0,94	0,041	0,038
0,03	20,8	0,53	0,82	0,056	23,9	24,5	0,62	0,68	0,90	0,92	0,046	0,042
0,04	19,5	0,47	0,80	0,068	23,3	23,9	0,59	0,65	0,88	0,90	0,051	0,045
0,05	18,5	0,42	0,78	0,078	22,8	23,2	0,57	0,62	0,86	0,88	0,054	0,046
0,06	17,7	0,39	0,77	0,089	22,4	22,7	0,56	0,60	0,85	0,86	0,056	0,048
0,07	17,1	0,35	0,76	0,096	22,1	22,4	0,54	0,58	0,84	0,85	0,058	0,049
0,08	16,6	0,33	0,75	0,102	21,9	22,1	0,53	0,56	0,83	0,84	0,06	0,051
0,09	16,2	0,31	0,74	0,109	21,8	21,9	0,51	0,54	0,82	0,83	0,062	0,052
0,10	15,8	0,29	0,73	0,115	21,7	21,7	0,50	0,52	0,81	0,82	0,063	0,053

(*) –метод VisuShrink, (**) – предложенный алгоритм вейвлет-фильтрации.




Рисунок 2.3 – Зависимость ПОСШ от дисперсии шума




Рисунок 2.4 – Зависимость SSIM от дисперсии шума




Рисунок 2.5 – Результаты обработки эталонного изображения

Результатом данного раздела стало подтверждение работоспособности идеи усиления НЧК в высокочастотных субполосах для повышения отношения сигнал-шум перед пороговой обработки. Результаты статистического моделирования на ЭВМ показали, что данный подход в целом эффективен, что подчеркивает необходимость дальнейших исследований и модификаций разработанного алгоритма. Также существует возможность использования этого алгоритма в сочетании с другими методами для повышения эффективности фильтрации изображений.

2.2 Адаптивный алгоритм пороговой обработки вейвлет-коэффициентов с локальной оценкой дисперсии шума с усилением НЧК

2.2.1 Адаптивный алгоритм пороговой обработки вейвлет-коэффициентов

В данном разделе предлагается адаптивный алгоритм вейвлет-фильтрации спекл-шума в РСА-изображениях, основанный на вейвлет-преобразовании. В отличие от традиционных подходов, данный алгоритм учитывает мультипликативную природу спекл-шума и его гетероскедастический характер без использования логарифмического преобразования. Нижеприведенное описание предложенного алгоритма процитировано из работы [133].

«Из выражений (1.1) и (1.3) следует, что при фиксированном значении интенсивности $X(i, j)$ условные математическое ожидание и дисперсия наблюдаемого сигнала определяются следующим образом:

$$\begin{aligned} E[Y(i, j) | X(i, j)] &= X(i, j), \\ \text{Var}[Y(i, j) | X(i, j)] &= \frac{X^2(i, j)}{L}. \end{aligned} \quad (2.1)$$

Из уравнения (2.1) следует ключевое свойство спекл-шума — его гетероскедастичность, заключающаяся в том, что дисперсия шумовой компоненты пропорциональна квадрату локальной интенсивности сигнала. Следовательно, в областях с высокой интенсивностью сигнала абсолютный уровень шума оказывается выше, чем в тёмных и слабоотражающих областях.

Данное свойство принципиально отличает спекл-шум от гомоскедастичного аддитивного шума, для которого дисперсия не зависит от локальной яркости изображения. Это обуславливает необходимость разработки алгоритмов фильтрации, учитывающих гетероскедастическую природу спекл-шума.

Предлагаемый алгоритм состоит из следующих шагов.

Шаг 1. Прямое вейвлет-преобразование.

К искаженному изображению применяется стационарное вейвлет-преобразование K -ого уровня, в результате чего формируются субполосы вейвлет-коэффициентов (LL_K, LH_K, HL_K, HH_K) ; $(LL_{K-1}, LH_{K-1}, HL_{K-1}, HH_{K-1})$; ...; (LL_1, LH_1, HL_1, HH_1) .

Шаг 2. Оценка эффективного значения $L_{эфф.}$ в пространстве вейвлет-коэффициентов.

В однородных областях изображения истинный сигнал $X(i, j)$ близок к константе, и, следовательно, коэффициенты субполосы LL_1 приближают локальное значение сигнала $X(i, j)$, тогда как субполоса HH_1 содержит в основном искаженные вейвлет-коэффициенты. Из модели спекл-шума (2.1) следует, что в таких областях выполняется:

$$Var(HH_1 | LL_1) \approx \frac{LL_1^2}{L}. \quad (2.2)$$

Для выделения однородных пикселей вычисляется локальная дисперсия коэффициентов $|HH_1|$ в скользящем окне размером $m \times m$.

Пусть H — множество таких пикселей. Тогда оценка $\hat{L}_{эфф.}$ вычисляется как:

$$\hat{L}_{эфф.} = med\left\{\frac{LL_K^2(i, j)}{Var_{лок}(|HH_1(i, j)|)} \mid (i, j) \in H\right\}, \quad (2.3)$$

где $Var_{лок}(|HH_1(i, j)|)$ — локальная дисперсия модуля коэффициентов HH_1 в окрестности точки (i, j) .

Шаг 3. Адаптивная оценка локального сигнала.

Для учёта гетероскедастичности спекл-шума величина порога должна зависеть от локальной интенсивности сигнала $X(i, j)$. В качестве оценки $\hat{X}_{лок}(i, j)$ используется абсолютное значение вейвлет-коэффициентов аппроксимации:

$$\hat{X}_{лок}(i, j) = |LL_K(i, j)|, \quad (2.4)$$

где $LL_K(x, y)$ — коэффициент аппроксимации на уровне K . Данная оценка устойчива к шуму и коррелирована с истинной интенсивностью отражающей способности.

Шаг 4. Адаптивная пороговая обработка.

На всех уровнях $k=1, \dots, K$ коэффициенты деталей подвергаются жесткой пороговой обработке с адаптивной величиной порога:

$$T(i, j) = \frac{1}{\sqrt{\hat{L}_{эфф}}} \cdot \hat{X}_{лок}(i, j) \cdot \sqrt{2 \ln(M \cdot N)}, \quad (2.5)$$

где $M \cdot N$ — общее число пикселей изображения. Величина порога, задаваемая формулой (2.5), следует из условной дисперсии спекл-шума $Var[Y | X] = \frac{X^2}{L}$ и обеспечивает подавление спекл-шума в зависимости от локальной интенсивности. Вейвлет-коэффициенты аппроксимации LL_K не изменяются.

Шаг 5. Обратное вейвлет-преобразование.

Выполняется обратное вейвлет-преобразование над обработанными вейвлет-коэффициентами, в результате чего вычисляется оценка изображения \hat{X} .»

Трудоёмкость алгоритма обусловлена вычислением локальной дисперсии в скользящем окне размером $m \times m$, что даёт теоретическую сложность $O(N^2 m^2)$. При фиксированном $m = 5$ асимптотика остаётся линейной по числу пикселей $O(N^2)$.

2.2.2 Результаты моделирования

Экспериментальная оценка эффективности предложенного алгоритма выполнена в программной среде Python на наборе из десяти эталонных изображений в градациях серого размером 512×512 пикселей, взятых из открытых баз данных TAMPERE17 и USC-SIPI. К каждому изображению был добавлен спекл-шум с дисперсией, варьируемой от 0,02 до 0,1. Для объективного сравнения

были реализованы два классических метода: фильтр Ли и метод, сочетающий логарифмическое преобразование с последующим применением адаптивной пороговой обработки вейвлет-коэффициентов BayesShrink. Методы на основе вейвлет-преобразования, включая предложенный, использовали биортогональный вейвлет bior4.4 при трёх уровнях декомпозиции. Оценка эффективности предложенного алгоритма проводилась по стандартным метрикам: ПОСШ, SSIM, MS-SSIM и GMSD. Результаты экспериментов усреднены по всем десяти тестовым изображениям и представлены в табл. 2.2, а также визуализированы на рис. 2.6 и рис. 2.7 в виде графиков для удобства анализа.

Таблица 2.2 – Результаты экспериментов

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		Фильтр Ли	BayesShrink	Предложенный
ПОСШ				
0,02	22,3	26,2	25,6	26,6
0,04	19,7	24,3	24,1	24,8
0,06	17,9	22,9	23,2	23,8
0,08	16,9	22,2	22,7	23,0
0,10	16,0	21,8	22,4	22,6
SSIM				
0,02	0,59	0,70	0,71	0,75
0,04	0,46	0,63	0,65	0,67
0,06	0,38	0,58	0,60	0,61
0,08	0,31	0,54	0,55	0,57
0,10	0,27	0,51	0,52	0,54
MS-SSIM				
0,02	0,83	0,90	0,91	0,94
0,04	0,79	0,86	0,87	0,89
0,06	0,76	0,83	0,84	0,85
0,08	0,73	0,80	0,81	0,83
0,10	0,69	0,78	0,79	0,80
GMSD				
0,02	0,042	0,035	0,037	0,033
0,04	0,065	0,043	0,044	0,040
0,06	0,085	0,048	0,047	0,043
0,08	0,098	0,052	0,050	0,046
0,10	0,110	0,056	0,052	0,050




Рисунок 2.6 – Зависимость ПОСШ от дисперсии шума




Рисунок 2.7 – Зависимость SSIM от дисперсии шума


Предложенный адаптивный алгоритм демонстрирует наилучшие средние значения по всем метрикам (ПОСШ, SSIM, MS-SSIM и GMSD), что свидетельствует об эффективном подавлении шума, точном сохранении структуры и минимизации артефактов.



а)



б)



в)



г)

Рисунок 2.8 – Результаты обработки РСА-изображения

На рис. 2.8 представлены результаты обработки реального РСА-изображения, полученного спутником StriX-1, предоставленного японской космической компанией Synspective. На рис. 2.8, а представлено исходное изображение со спекл-шумом, а на рис. 2.8,б, 2.8,в и 2.8,г представлены изображения, обработанные фильтром Ли, с помощью метода BayesShrink и предложенным алгоритмом соответственно. Из рис. 2.8 видно, что фильтр Ли размывает мелкие структуры, тогда как метод вейвлет-фильтрации с пороговой обработкой вейвлет-коэффициентов BayesShrink оставляет остаточный шум в сегментах с однородной текстурой. Предложенный алгоритм обеспечивает эффективное подавление шума при сохранении четкости контурных элементов и границ, а также демонстрирует высокую степень однородности фона.

2.3 Алгоритмы комбинированной фильтрации спекл-шума с усилением НЧК в высокочастотных субполосах

Как показано в разделах 1.2 и 1.4, каждая группа методов подавления спекл-шума характеризуется определёнными преимуществами и ограничениями [15, 23, 67, 70–75]. В связи с этим одним из перспективных направлений повышения эффективности шумоподавления является использование комбинированной фильтрации [121–122, 126–127].

В данном разделе рассматриваются три подхода к комбинированию методов фильтрации спекл-шума: последовательное применение нескольких фильтров; комбинированная фильтрация на основе текстурного анализа, предусматривающая использование различных методов для однородных и неоднородных областей изображения; а также совместное применение пороговой обработки и пространственной фильтрации в области вейвлет-коэффициентов.

2.3.1 Комбинирование пространственных и частотных методов фильтрации спекл-шума

Комбинирование пространственной и частотной фильтрации основано на последовательном применении фильтров. На первом этапе изображение подвергается пространственной фильтрации для первичного снижения уровня шума. На втором этапе осуществляется частотная фильтрация, позволяющая выполнить более точную настройку и подавление оставшихся высокочастотных компонентов шума, не устранённых на первом этапе. Альтернативным подходом является обратная последовательность: сначала применяются частотные фильтры для подавления высокочастотного шума, а затем пространственные фильтры для устранения артефактов, возникающих в результате частотной фильтрации [134].

Комбинирование пространственной и частотной фильтрации может быть реализовано в различных последовательностях, эффективность которых зависит от конкретного выбора методов фильтрации. В данном исследовании оценена эффективность четырех комбинированных подходов. Пространственная фильтрация осуществлялась с использованием усредняющего и медианного

фильтров, характеризующихся низкими вычислительными затратами и высокой скоростью обработки. В качестве частотного фильтра был использован вейвлет-фильтр. Экспериментальная оценка была выполнена для всех четырех различных комбинационных подходов [134]:

- 1) вейвлет-фильтр + усредняющий фильтр: W-M.
- 2) вейвлет-фильтр + медианный фильтр: W-MD.
- 3) усредняющий фильтр + вейвлет-фильтр M-W.
- 4) медианный фильтр + вейвлет-фильтр MD-W.

Последовательное применение метода вейвлет-фильтрации и пространственного фильтра (усредняющего или медианного) сохраняет общую асимптотическую сложность $O(N^2)$, поскольку каждый этап выполняется за линейное время относительно числа пикселей.

2.3.2 Комбинированная фильтрация спекл-шума на основе текстурного анализа

Существующие методы фильтрации спекл-шума не всегда обеспечивают оптимальный баланс между степенью шумоподавления и сохранением информативных деталей изображения, особенно при обработке сцен, содержащих одновременно однородные и текстурированные области. В связи с этим в настоящем разделе предлагается алгоритм комбинированной фильтрации спекл-шума, основанный на текстурном анализе изображения [120–122, 135].

Из материалов, представленных в разделе 1.2, а также результатов компьютерного моделирования, приведённых в разделе 1.4, следует, что фильтр Винера обеспечивает эффективное подавление шума в однородных областях изображения [75–78, 129–130]. В то же время модифицированный алгоритм пороговой обработки вейвлет-коэффициентов с усилением НЧК демонстрирует высокую эффективность при обработке неоднородных, в том числе текстурированных, областей. Как было показано ранее, данный алгоритм способствует подавлению шумовой составляющей и ограничивает появление артефактов на границах объектов и участках с резкими перепадами яркости. На

этой основе предлагаемый алгоритм реализует предварительную сегментацию изображения по критерию однородности с последующим применением соответствующего фильтра к каждому выделенному классу областей [135].

Предлагаемый алгоритм включает в себя следующие шаги.

1. Выделение однородных и неоднородных областей изображения.

Для решения данной задачи используется метод текстурного анализа, основанный на локальных статистических характеристиках изображения. Критерием разделения служит характер изменения интенсивности пикселей в пределах локальной области. Однородные области характеризуются низкой вариацией интенсивности, тогда как неоднородные области содержат выраженные границы, текстурные элементы и значительные локальные перепады яркости.

В качестве количественной меры однородности используется локальная дисперсия $\sigma^2(i, j)$ в окне размером $m \times m$, определяемая следующим выражением:

$$\sigma^2(i, j) = \frac{1}{Q} \sum_{u=-k}^k \sum_{v=-k}^k [I(i+u, j+v) - \mu(i, j)]^2, \quad (2.6)$$

где $k = \frac{m-1}{2}$, Q — количество пикселей в окне размером $m \times m$ с центром в пикселе (i, j) ; $I(i+u, j+v)$ представляет интенсивность пикселя в позиции $(i+u, j+v)$; $\mu(i, j)$ — локальное математическое ожидание.

Значение локальной дисперсии сравнивается с порогом λ , оптимальное значение которого определялось методом Отсу. В настоящей работе при формировании представленных экспериментальных результатов использовалось значение $\lambda=0,05$ для окна размером 5×5 . Тогда однородной областью является область со значением локальной дисперсии меньше λ , а неоднородной областью является область со значением локальной дисперсии выше или равным λ . Для повышения точности выделения однородных областей применяется предварительное сглаживание изображения фильтром Гаусса, позволяющее уменьшить влияние высокочастотного шума и несущественных локальных вариаций интенсивности [135].

2. Фильтрация по областям.

После сегментации изображения по критерию однородности для каждого класса областей используется соответствующий метод фильтрации: модифицированный алгоритм пороговой обработки вейвлет-коэффициентов применяется к неоднородным областям, а фильтр Винера — к однородным областям.

Вычислительные затраты алгоритма складываются из этапа текстурной сегментации на основе локальной дисперсии $O(N^2 \cdot m^2)$ и условного применения фильтра Винера или вейвлет-пороговой обработки $O(N^2)$.

2.3.3 Комбинированная фильтрация спекл-шума на основе вейвлет-преобразования и метода нелокального усреднения

Несмотря на свою относительную эффективность в подавлении шума, при непосредственном применении к изображению метод NLM обрабатывает все пространственные компоненты одинаково, не различая низко- и высокочастотные структуры. Это может привести к потере мелких деталей или к неполному подавлению шума в однородных областях [58–64]. В данном разделе предлагается комбинированная фильтрация спекл-шума, при которой обработка вейвлет-коэффициентов осуществляется с использованием метода NLM. Описание предложенного подхода, приведённое ниже, взято из работы [136].

«В отличие от классической реализации, в данной работе метод NLM не применяется непосредственно к изображению на уровне пикселей, а используется для обработки вейвлет-коэффициентов, что позволяет учитывать частотно-пространственную структуру изображения и повысить эффективность подавления спекл-шума.

Алгоритм фильтрации включает следующие шаги:

Шаг 1. Прямое вейвлет-преобразование.

К искажённому изображению применяется СВП первого уровня, в результате чего формируются четыре субполосы (LL_1 , LH_1 , HL_1 , HH_1).

Шаг 2. Оценка уровня шума.

Для оценки стандартного отклонения шума σ используются коэффициенты самой высокочастотной субполосы HH_1 :

$$\sigma = -\frac{\text{median}(|HH_1|)}{0,674}. \quad (2.7)$$

Шаг 3. Обработка субполос вейвлет-коэффициентов.

Коэффициенты субполосы аппроксимации (LL_1) обрабатываются непосредственно методом NLM, поскольку в этой субполосе сосредоточены НЧК — в частности, гладкие области, крупномасштабные формы и общая геометрия объектов. Из-за относительно низкой чувствительности коэффициентов субполосы LL_1 к шуму применение метода NLM к данной субполосе обеспечивает эффективное подавление шумов в низкочастотной составляющей изображения, при этом сохраняется глобальная структура изображения.

В отличие от низкочастотных коэффициентов (LL_1), высокочастотные коэффициенты (LH_1 , HL_1 , HH_1) наиболее чувствительны к шуму. Поэтому обработка таких вейвлет-коэффициентов осуществляется в два последовательных этапа. На первом этапе применяется метод пороговой обработки с использованием адаптивного порога BayesShrink. Предварительная пороговая обработка позволяет значительно снизить количество шумовых коэффициентов. Это не только ускоряет последующий этап поиска похожих патчей в рамках метода NLM, но и повышает его точность, способствуя лучшему сохранению важных деталей. На втором этапе к полученным после пороговой обработки субполосам деталей применяется метод NLM, направленный на удаление остаточного шума и устранение артефактов, возникающих в результате пороговой обработки.

Шаг 4. Обратное вейвлет-преобразование.

Выполняется обратное СВП над обработанными субполосами вейвлет-коэффициентов. В результате получается оценка оригинала изображения.»

Вычислительная сложность алгоритма определяется асимптотикой $O(N^2S^2P^2)$ по времени и $O(N^2S^2)$ по памяти, где S и P — размеры окна поиска и патча соответственно.

2.3.4 Результаты моделирования

В этом разделе представлены результаты моделирования, демонстрирующие эффективность алгоритмов в комбинированной фильтрации, предложенных в разделах 2.3.1, 2.3.2 и 2.3.3.

2.3.4.1. Результаты моделирования методов комбинирования пространственной и частотной фильтрации

Результаты эксперимента для сравнения различных комбинационных подходов пространственной и частотной фильтрации спекл-шума представлены в табл. 2.3 и на рис. 2.9 и 2.10.




Рисунок 2.9 – Зависимость ПОСШ от дисперсии шума




Рисунок 2.10 – Зависимость SSIM от дисперсии шума

Таблица 2.3 – Результаты экспериментов

Дисперсия шума	Зашум. изобр.	Восстановленное изображение						
		Median	Mean	VisuShrink	W-M	MD- W	M-W	W- MD
ПОСШ								
0,02	22,4	23,0	23,7	25,1	24,8	23,4	25,8	25,4
0,04	19,8	21,3	22,5	24,0	23,5	21,9	23,7	24,1
0,06	18,0	20,0	21,7	23,0	22,4	20,7	22,4	23,3
0,08	17,1	19,2	21,0	22,4	21,6	19,8	21,7	22,7
0,10	16,1	18,5	20,6	22,0	21,0	19,1	21,0	22,3
SSIM								
0,02	0,60	0,61	0,63	0,65	0,67	0,62	0,66	0,66
0,04	0,47	0,53	0,56	0,59	0,58	0,55	0,58	0,60
0,06	0,38	0,47	0,51	0,55	0,54	0,50	0,54	0,57
0,08	0,32	0,43	0,47	0,53	0,51	0,46	0,52	0,54
0,10	0,28	0,40	0,45	0,51	0,48	0,43	0,50	0,53
MS-SSIM								
0,02	0,81	0,85	0,86	0,87	0,89	0,85	0,88	0,88
0,04	0,74	0,79	0,81	0,83	0,83	0,81	0,83	0,84
0,06	0,69	0,76	0,78	0,81	0,8	0,78	0,8	0,82
0,08	0,65	0,73	0,76	0,79	0,78	0,75	0,79	0,80
0,10	0,62	0,71	0,74	0,78	0,76	0,73	0,78	0,79
GMSD								
0,02	0,042	0,054	0,052	0,037	0,035	0,041	0,038	0,033
0,04	0,067	0,071	0,069	0,047	0,045	0,053	0,048	0,042
0,06	0,088	0,086	0,084	0,055	0,052	0,061	0,056	0,048
0,08	0,100	0,096	0,094	0,063	0,060	0,069	0,064	0,054
0,10	0,113	0,109	0,106	0,070	0,067	0,076	0,071	0,059

Анализ результатов эксперимента продемонстрировал, что применение комбинированных фильтров обеспечивает более высокую эффективность подавления спекл-шума по сравнению с использованием только одного фильтра. Данные, представленные в табл. 2.3 и на рис. 2.9, рис 2.10 свидетельствуют о том, что последовательное применение частотного фильтра с последующим пространственным фильтром является результативным подходом. Это обусловлено тем, что частотный фильтр эффективно подавляет высокочастотные

компоненты шума, в то время как пространственный фильтр, применяемый на следующем этапе, предназначен для минимизации артефактов, индуцированных частотной обработкой, и повышения однородности фона изображения. Применение комбинации фильтров в обратной последовательности не является таким результативным, как в первом случае, поскольку предварительное использование пространственного фильтра может привести к снижению отношения сигнал-шум, что, в свою очередь, ухудшает эффективность частотной фильтрации. Результаты экспериментальных исследований показывают, что последовательная схема «вейвлет-фильтрация + медианный фильтр» (W-MD) обеспечивает наивысшие значения ПОСШ и SSIM при наименьшем GMSD среди всех комбинаций. Это обусловлено тем, что медианный фильтр, в отличие от усредняющего, обладает улучшенной способностью сохранения контуров.

2.3.4.2. Результаты моделирования алгоритма комбинированной фильтрации спекл-шума на основе текстурного анализа

Результаты экспериментов для оценки эффективности предложенного алгоритма представлены в табл. 2.4 и на рис. 2.11 и 2.12.




Рисунок 2.11 – Зависимость ПОСШ от дисперсии шума

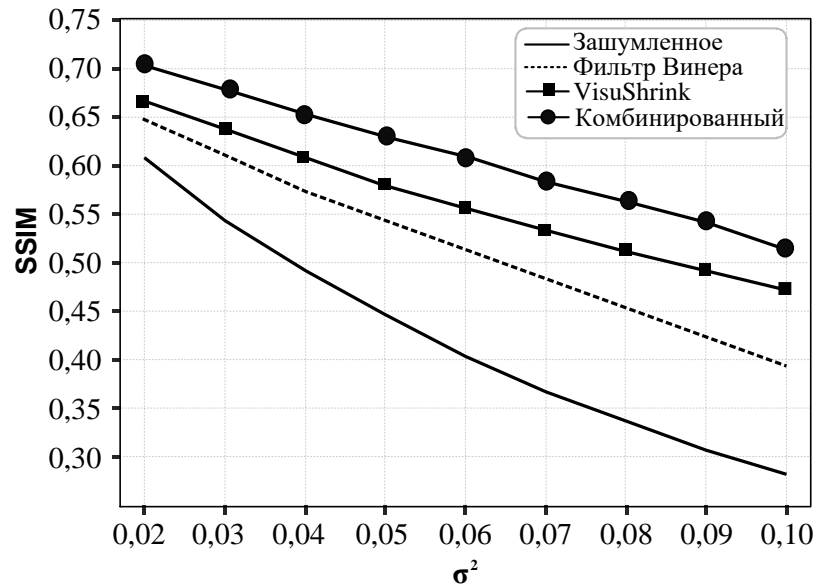


Рисунок 2.12 – Зависимость SSIM от дисперсии шума

Таблица 2.4 – Результаты экспериментов

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		Фильтр Винера	VisuShrink	Комбинированный
ПОСШ				
0,02	22,4	26	24,9	25,6
0,04	19,8	23,6	23,4	24,1
0,06	18,0	22,1	22,6	23,3
0,08	16,7	21,1	22,1	22,9
0,10	15,9	20,5	21,8	22,5
SSIM				
0,02	0,59	0,65	0,67	0,71
0,04	0,46	0,58	0,62	0,65
0,06	0,38	0,52	0,56	0,61
0,08	0,32	0,46	0,52	0,57
0,10	0,28	0,40	0,48	0,52
MS-SSIM				
0,02	0,84	0,87	0,88	0,90
0,04	0,76	0,82	0,85	0,86
0,06	0,70	0,78	0,81	0,83
0,08	0,67	0,74	0,78	0,81
0,10	0,65	0,70	0,76	0,78
GMSD				
0,02	0,042	0,035	0,038	0,033
0,04	0,065	0,043	0,045	0,039
0,06	0,085	0,048	0,045	0,041
0,08	0,098	0,052	0,047	0,044
0,10	0,110	0,056	0,050	0,048

Алгоритм комбинированной изолированных фильтрации на основе текстурного анализа превосходит методы Винера и вейвлет-пороговой обработки, демонстрируя стабильное повышение ПОСШ, SSIM, MS-SSIM и снижение GMSD. Эти результаты подтверждают эффективное сглаживание фона без искажений, точное сохранение границ и текстур, а также минимизацию эффекта «звона».

2.3.4.3. Результаты моделирования алгоритма комбинированной фильтрации спекл-шума, на основе вейвлет-преобразования и метода NLM

Результаты экспериментов, оценивающие эффективность алгоритма комбинированной фильтрации спекл-шума, на основе вейвлет-преобразования и метода нелокального усреднения, представлены в табл. 2.5 и на рис. 2.13, рис. 2.14.

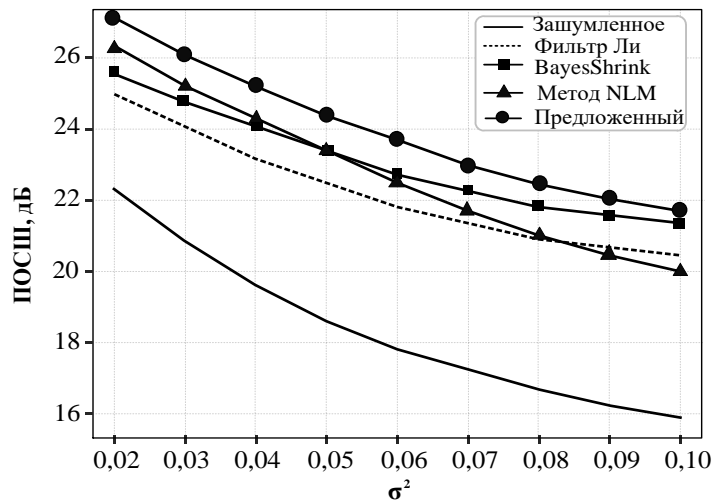


Рисунок 2.13 – Зависимость ПОСШ от дисперсии шума




Рисунок 2.14 – Зависимость SSIM от дисперсии шума

Таблица 2.5 – Результаты экспериментов

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение			
		Фильтр Ли	BayesShrink	NLM	Предложенный
ПОСШ					
0,02	22,3	24,9	25,5	26,2	27,0
0,04	19,6	23,1	24,0	24,4	25,1
0,06	17,8	21,8	22,7	22,5	23,7
0,08	16,7	21,0	21,8	21,1	22,4
0,10	16,1	20,5	21,4	20,0	21,7
SSIM					
0,02	0,58	0,69	0,71	0,74	0,77
0,04	0,46	0,62	0,64	0,64	0,70
0,06	0,37	0,57	0,60	0,57	0,63
0,08	0,31	0,53	0,56	0,52	0,58
0,10	0,27	0,51	0,52	0,49	0,54
MS-SSIM					
0,02	0,83	0,90	0,92	0,93	0,95
0,04	0,75	0,86	0,86	0,87	0,91
0,06	0,69	0,82	0,85	0,82	0,86
0,08	0,65	0,80	0,82	0,79	0,83
0,10	0,63	0,78	0,80	0,77	0,80
GMSD					
0,02	0,043	0,039	0,036	0,033	0,031
0,04	0,066	0,047	0,043	0,040	0,038
0,06	0,087	0,051	0,046	0,048	0,042
0,08	0,101	0,055	0,048	0,052	0,045
0,10	0,112	0,056	0,050	0,062	0,047

Результаты моделирования показали, что метод NLM, работающий на уровне пикселей, эффективен лишь при слабом шуме, тогда как при росте его интенсивности качество обработки резко снижается. В отличие от него, комбинированный алгоритм сохраняет стабильно высокие показатели при любых уровнях шума, обеспечивая максимальные значения ПОСШ и SSIM при минимальном GMSD. Это подтверждает эффективное подавление спекл-шума, точное сохранение структурных деталей и минимизацию артефактов.

2.4 Алгоритм фильтрации зашумленных изображений с использованием нейронной сети U-Net в области вейвлет-преобразования

2.4.1 Архитектура U-Net для обработки субполос вейвлет-коэффициентов

Традиционные CNN-модели, работающие непосредственно в пространственной области пикселей, относительно уверенно подавляют аддитивный шум, но показывают нестабильные результаты при наличии спекла. Кроме того, наблюдается потеря мелких деталей и искажения текстур вследствие переобучения нейронных сетей [89, 92, 107, 108].

Для преодоления указанных ограничений перспективным направлением является разработка алгоритмов, комбинирующих вейвлет-преобразование и преимущества нейронной сети U-Net [67–71, 74, 137–139]. Такой подход позволяет анализировать особенности изображения на разных масштабах, что способствует выделению полезного сигнала на фоне шума. Для описания данного подхода ниже цитируются соответствующие фрагменты работ [137].

«Предложенный алгоритм использует вейвлет-преобразование для декомпозиции изображения на множества вейвлет-коэффициентов в субполосах (LL , LH , HL , HH). Поскольку спекл преимущественно проявляется в высокочастотных субполосах, то для их обработки используется нейронная сеть U-Net, которая эффективна благодаря своей симметричной структуре, включающей пути энкодера и декодера, дополненные пропускными связями. Такие связи позволяют нейронная сеть точно сохранять и восстанавливать важные детали изображения, утраченные при пороговой обработке вейвлет-коэффициентов. Кроме того, усиление НЧК в высокочастотных субполосах для повышения отношения сигнал-шум позволяет нейронная сеть U-Net точнее отделять информативные структуры сигнала от шума. В результате предложенная комбинация вейвлет-преобразования и нейронной сети U-Net обеспечивает высокоэффективное подавление спекл-шума, минимизируя потери важной визуальной информации и сохраняя резкость деталей [90, 104–108].

Задача подавления спекл-шума сводится к процессу получения оценки оригинала X из зашумленного изображения Y . В контексте глубокого обучения задача заключается в обучении некоторой параметризованной нелинейной функции F_θ , отображающей зашумленное изображение Y на соответствующее неискаженное изображение X :

$$F_\theta(Y) \approx X, \quad (2.8)$$

где θ — параметры глубокой нейронной сети.

Функция F_θ обучается на наборе размеченных пар $\{(Y_i, X_i)\}_{i=1}^N$, где Y_i , $i = \overline{1, N}$, — смоделированные зашумленные изображения, для которых известны соответствующие им оригиналы X_i . Обучение осуществляется путем минимизации функции потерь, например СКО, L1-Loss или SSIM между оценкой оригинала (предсказание) и самим оригиналом (целевое значение). Таким образом, после обучения с помощью параметризованной функции F_θ можно обрабатывать произвольные зашумленные входные изображения, для которых оригинал неизвестен. Эффективность функции F_θ оценивается ее способностью к обобщению на новые, ранее не встречавшиеся изображения.

В отличие от известных подходов, в которых нейронные сети оперируют непосредственно с пикселями изображений, предлагаемый алгоритм работает в области вейвлет-трансформанты. Особенностью алгоритма является обучение нейронной сети U-Net с целью предсказания карты шума $K_{\text{пред}}$ для вейвлет-коэффициентов вместо вычисления оценки оригинала X . Модель нейронной сети предсказывает разности $O_{\text{пред}}$ между вейвлет-коэффициентами зашумленного ($W_{\text{зашум}}$) и неискаженного изображений ($W_{\text{чист}}$), полученных с помощью вейвлет-преобразования. Оценка оригинала вычисляется путем обратного вейвлет-преобразования на основе оценок вейвлет-коэффициентов $W_{\text{очищ}} = W_{\text{зашум}} - O_{\text{пред}}$.

Предлагаемая архитектура нейронной сети U-Net принимает на вход тензор размерности $[B, 4, H, W]$, где 4 канала представляют собой потоки вейвлет-коэффициентов субполос (LL , LH , HL , HH), полученных после СВП

зашумленного изображения. Энкодер построен как последовательность модулей двойной свёртки, в которых количество признаков каналов экспоненциально возрастает от 32 до 1024 при одновременном уменьшении пространственного разрешения в два раза на каждом уровне за счёт применения операций двумерного максимального пулинга. Конкретная последовательность преобразования каналов, следующая: входной тензор с 4 каналами сначала проецируется в 32 признаковых канала, после чего последовательно увеличивается по схеме $32 \rightarrow 64 \rightarrow 128 \rightarrow 256 \rightarrow 512$. Декодер организован симметрично энкодеру: на каждом уровне он восстанавливает пространственное разрешение, используя транспонированные свёртки, что обеспечивает контролируемый и обучаемый процесс апсемплинга (up-sampling). Критически важной особенностью является использование пропускных связей, которые конкатенируют признаки декодера с соответствующими картами признаков энкодера по каналу (например, при $\text{init_features} = 32$: $256 + 256 \rightarrow 512 \rightarrow 256$), сохраняя как глобальный контекст, так и локальные детали частотных поддиапазонов. Финальный двумерный сверточный слой $\text{Conv2d}(32, 4, 1)$ преобразует полученные признаки в четырехканальный тензор, представляющий собой оценку вейвлет-коэффициентов шума. Итоговое восстановление чистых субполос выполняется за пределами архитектуры, что обеспечивает более стабильную оптимизацию и лучшее сохранение высокочастотных деталей [34, 38, 92, 107].

Для упрощения задачи обучения применяется метод остаточного обучения: предлагаемая нейронная сеть обучается предсказывать разность между вейвлет-коэффициентами соответствующих субполос зашумленного и оригинального изображений $O_{\text{пред}} = W_{\text{зашум}} - W_{\text{чист}}$. Это упрощает задачу обучения, поскольку сеть фокусируется на моделировании отклонений, вызванных шумом, а не на реконструкции полного набора вейвлет-коэффициентов. Такой подход снижает сложность целевой функции и сужает пространство решений, позволяя модели эффективнее выявлять и компенсировать шумовые компоненты. На выходе сети формируется шумовая компонента вейвлет-коэффициентов $O_{\text{пред}}$, которая

вычитается из исходных зашумлённых коэффициентов $W_{\text{зашум}}$, что даёт очищенные коэффициенты $W_{\text{очищ}} = W_{\text{зашум}} - O_{\text{пред}}$.

Для оптимизации параметров модели предлагается использовать комбинированную функцию потерь:

$$\begin{aligned} Loss_{\text{общ.}} = & W_{LL} * (\alpha * L1_{LL} + (1 - \alpha) * (1 - SSIM_{LL})) + \\ & W_{HL} * (\beta * L1_{HL} + (1 - \beta) * (1 - SSIM_{HL})) + \\ & W_{LH} * (\beta * L1_{LH} + (1 - \beta) * (1 - SSIM_{LH})) + \\ & W_{HH} * (\beta * L1_{HH} + (1 - \beta) * (1 - SSIM_{HH})). \end{aligned} \quad (2.9)$$

Данная функция состоит из двух основных компонентов: L1-Loss и SSIM Loss. Комбинированный подход учитывает особенности каждого из четырех субполос вейвлет-коэффициентов, применяя дифференцированную стратегию: для низкочастотной субполосы LL, несущей основную структурную информацию изображения, приоритет отдается L1-Loss, который эффективно минимизирует абсолютные ошибки интенсивности пикселей и способствует точному восстановлению глобальных характеристик. Для высокочастотных субполос LH, HL и HH, содержащих детализированную информацию о границах и текстурах, предпочтение отдается SSIM, как метрике, более точно отражающей структурное сходство и лучше сохраняющей визуальное качество мелких деталей. Общая формула потерь является взвешенной суммой компонентов с рекомендованными весами для L1-Loss в LL канале и для SSIM в LH, HL и HH каналах (субполосах). Такое взвешивание обеспечивает оптимальный компромисс между эффективным подавлением шума и сохранением как глобальных структурных характеристик изображения, так и локальных текстурных деталей [83, 84, 92, 107].»

2.4.2 Алгоритм фильтрации зашумленных изображений с использованием нейронной сети U-Net.

2.4.2.1. Подготовка обучающих данных

Набор изображений, используемых для обучения и тестирования модели, взятых из открытых баз данных TAMPERE17 и USC-SIPI. Из них 50 изображений использовались для обучения модели, а 10 — для тестирования.

Для формирования соответствующих зашумленных изображений с помощью датчика случайных чисел моделировался спекл-шум с единичным средним и задаваемой дисперсией в среде моделирования Python.

2.4.2.2. Использование обученной модели для обработки зашумленных изображений

Предлагаемый алгоритм включает следующие шаги.

Шаг 1. Вейвлет-декомпозиция. Применение СВП первого уровня к изображению. В результате получается 4 субполосы: LL_1 , LH_1 , HL_1 , HH_1 .

Шаг 2. Усиление НЧК в высокочастотных субполосах. Для субполосы LL_1 выполняется СВП с целью получения соответствующих субполос LL_2 , LH_2 , HL_2 , HH_2 . Для усиления НЧК в высокочастотных субполосах производится суммирование вейвлет-коэффициентов деталей, полученных в результате СВП первого уровня, с вейвлет-коэффициентами деталей LH_2 , HL_2 , HH_2 . В результате формируются новые массивы вейвлет-коэффициентов LH_{1y} , HL_{1y} , HH_{1y} .

Шаг 3. Подавление шума с использованием нейронной сети U-Net. Модифицированные высокочастотные субполосы (объединяются в трёхканальное представление) конкатенируются с субполосой LL_1 (как четвертый канал) и подаются на вход U-Net. Сеть обучается предсказывать карту шума субполос.

Шаг 4: Формирование оценки оригинала (то есть очищенного от спекл-шума) изображения осуществляется путём вычитания предсказанных U-Net шумовых составляющих из соответствующих вейвлет-коэффициентов субполос с последующим применением обратного СВП.

Вычислительная сложность W-UNet составляет $O(N^2 \cdot K)$, где K — константа, зависящая от числа каналов и размеров ядер свёртки. Сложность по памяти — $O(N^2 + P_U)$, где P_U — число параметров.

2.4.3 Результаты моделирования

Экспериментальная оценка эффективности предлагаемой архитектуры W-UNet проводилась в программной среде Python на наборе из 60 эталонных полутоновых изображений размером 512×512 пикселей (50 — для обучения, 10 — для тестирования), полученных из открытых наборов данных TAMPERE17 и

USC-SIPI. К каждому изображению применялся мультипликативный спекл-шум, моделируемый гамма-распределением с дисперсией, изменяющейся в диапазоне от 0,02 до 0,1. В качестве базовых методов сравнения были выбраны две широко известные нейросетевые архитектуры — DnCNN и U-Net. Обучение всех моделей осуществлялось в идентичных условиях с использованием стратегии остаточного обучения и оптимизатора AdamW при начальной скорости обучения $5 \cdot 10^{-4}$ и коэффициенте затухания весов 10^{-6} в течение 50 эпох. на протяжении 50 эпох. Результаты экспериментов, усреднённые по десяти тестовым изображениям, представлены в табл. 2.6 и проиллюстрированы на рис. 2.15 и 2.16.

Таблица 2.6 – Результаты экспериментов

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		DnCNN	U-Net	Wavelet-UNet
ПОСШ				
0,02	22,2	26,4	27,8	28,7
0,04	19,3	24,8	25,8	26,6
0,06	17,4	23,5	24,1	24,9
0,08	16,4	22,4	22,8	23,0
0,10	15,7	21,6	22,3	22,5
SSIM				
0,02	0,58	0,73	0,76	0,79
0,04	0,46	0,66	0,68	0,71
0,06	0,38	0,60	0,63	0,65
0,08	0,32	0,55	0,59	0,60
0,10	0,28	0,53	0,56	0,57
MS-SSIM				
0,02	0,83	0,92	0,94	0,96
0,04	0,75	0,88	0,90	0,92
0,06	0,70	0,85	0,87	0,89
0,08	0,66	0,83	0,85	0,87
0,10	0,63	0,80	0,83	0,84
GMSD				
0,02	0,042	0,037	0,033	0,030
0,04	0,066	0,045	0,041	0,038
0,06	0,087	0,047	0,044	0,041
0,08	0,101	0,051	0,048	0,046
0,10	0,113	0,053	0,051	0,050




Рисунок 2.15 – Зависимость ПОСШ от дисперсии шума




Рисунок 2.16 – Зависимость SSIM от дисперсии шума. Полученные экспериментальные данные демонстрируют эффективность предложенного алгоритма по сравнению с другими современными методами шумоподавления на основе глубокого обучения — DnCNN и базовой нейронной сетью U-Net,

оперирующей в пространственной области по всем используемым объективным метрикам качества. Результаты экспериментов также показывают, что при усилении НЧК в высокочастотных субполосах улучшаются значения метрик качества. Данный результат особенно характерен для критерия SSIM, который отражает информацию о текстуре изображения. Тем не менее, следует отметить, что эффективность предложенного алгоритма снижается с увеличением интенсивности спекл-шума. Это объясняется тем, что при низком отношении сигнал-шум усиление НЧК в высокочастотных субполосах может привести к увеличению не только полезных структурных составляющих, но и шума, который в них присутствует, что снижает эффективность подавления шума.

2.5 Выводы по второй главе

Во второй главе разработаны и исследованы алгоритмы анализа и фильтрации изображений, искаженных спекл-шумом, на основе вейвлет-преобразования с усилением НЧК в высокочастотных субполосах.

1. Разработан модифицированный алгоритм пороговой обработки вейвлет-коэффициентов с усилением НЧК в высокочастотных субполосах. Установлено, что такое усиление при пороговой обработке вейвлет-коэффициентов обеспечивает увеличение отношения сигнал-шум и тем самым увеличивает эффективность фильтрации изображений, искажённых спекл-шумом.

2. Разработан адаптивный алгоритм пороговой обработки вейвлет-коэффициентов с локальной оценкой дисперсии шума при усилении НЧК. Установлено, что использование адаптивного порога, формируемого с учётом локальной оценки дисперсии шума, обеспечивает компромисс между подавлением шума и сохранением мелких деталей, текстурных особенностей и границ объектов.

3. Разработан алгоритм фильтрации зашумленных изображений на основе модифицированной пороговой вейвлет-обработки и фильтра Винера с использованием текстурного анализа. Показано, что учёт текстурных характеристик изображения позволяет выполнять локально-адаптивную обработку однородных и неоднородных областей, что способствует повышению

эффективности шумоподавления при сохранении информативных деталей и контурной структуры изображения.

4. Разработан алгоритм фильтрации зашумленных изображений на основе применения метода NLM в области вейвлет-преобразования. Установлено, что совместное использование многомасштабного вейвлет-представления и нелокального усреднения позволяет повысить качество фильтрации за счёт анализа сходства локальных структур вейвлет-коэффициентов.

5. Разработан алгоритм фильтрации зашумленных изображений на основе применения архитектуры нейронной сети U-Net в области вейвлет-преобразования. Показано, что сочетание многомасштабного вейвлет-представления с возможностями нейросетевой обработки обеспечивает высокое качество восстановления изображений, способствует сохранению мелких деталей и яркости фона восстановленного изображения.

ГЛАВА 3. АЛГОРИТМЫ АНАЛИЗА И ФИЛЬТРАЦИИ ЗАШУМЛЕННЫХ ИЗОБРАЖЕНИЙ НА ОСНОВЕ ОБРАБОТКИ ПРОСТРАНСТВЕННО-ОРИЕНТИРОВАННЫХ ДЕРЕВЬЕВ ВЕЙВЛЕТ- ПРЕОБРАЗОВАНИЯ.

3.1 Пространственно-ориентированные деревья вейвлет-преобразования

Пространственно-ориентированные деревья (ПОД) вейвлет-преобразования представляют собой структурированную модель, отражающую иерархическую организацию вейвлет-коэффициентов в кратномасштабном пространстве [124, 125]. Такое представление позволяет явно моделировать пространственные и масштабные зависимости между вейвлет-коэффициентами. Вейвлет-коэффициенты на высоких масштабах пространственно соотносятся с блоками вейвлет-коэффициентов на мелких масштабах. Эта пространственная иерархия естественным образом формирует дерево, в котором корень дерева (точка 1) соответствует коэффициенту аппроксимации, находящемуся на самом последнем уровне декомпозиции. Каждый узел (коэффициент) на уровне k имеет четырёх потомков на уровне $k-1$. Эти потомки пространственно отображают область, охватываемую родительским узлом, формируя таким образом иерархическую структуру. Точки последнего уровня, или листья, в данной древовидной структуре не имеют потомков [124, 127, 128, 138, 139].

Пусть $w_{k,o}(i, j)$ обозначает вейвлет-коэффициент на уровне k , ориентации $O \in \{H, V, D\}$ и пространственной позиции (i, j) . Тогда ПОД, корень которого расположен в (i_0, j_0) на самом верхнем уровне K , определяется рекурсивно как:

$$T_{L,i_0,j_0}^{(o)} = \left\{ w_{k,o}(i, j) \mid k = K, K-1, K-2, \dots, 1; (i, j) \in W_k(i_0, j_0) \right\}, \quad (3.1)$$

где $W_k(i_0, j_0)$ — множество позиций на уровне k , соответствующих пространственному «наследию» корня (i_0, j_0) .

Ключевая идея построения ПОД заключается в том, что вейвлет-коэффициенты, соответствующие одному и тому же пространственному

местоположению на различных уровнях декомпозиции, имеют статистическую взаимосвязь. Другими словами, если какой-то элемент изображения имеет заметный признак (например, край, контур), его вейвлет-коэффициенты, соответствующие этому местоположению, будут значительными на нескольких уровнях. Данное свойство позволяет учитывать корреляционные зависимости между масштабами при анализе и фильтрации изображений, что способствует более эффективному подавлению шума и сохранению информативных деталей. Пример структуры ПОД для трёхуровневого БВП представлен на рис. 3.1.

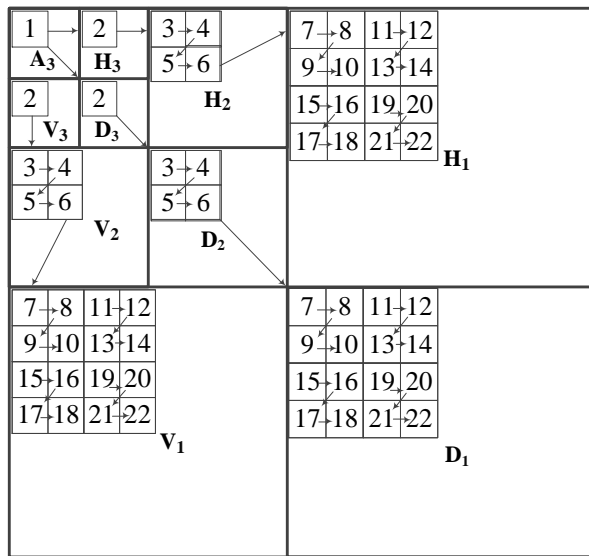


Рисунок 3.1 – Структура ПОД для трёхуровневого БВП

Неискажённые изображения могут быть описаны как совокупность кусочно-регулярных структур, для которых характерна локальная однородность – то есть плавное изменение значений интенсивности пикселей в пределах однородных текстурных или геометрических регионов. При вейвлет-декомпозиции таких изображений коэффициенты, организованные в рамках ПОД, демонстрируют упорядоченное и монотонное убывание амплитуд по уровням декомпозиции: значимые коэффициенты сосредоточены вблизи особенностей (границ, углов), а в однородных областях они стремятся к нулю плавно, без резких скачков. При наличии шума кусочно-регулярная структура сигнала нарушается – в однородных областях появляются ложные высокочастотные компоненты, что приводит к хаотичному распределению и аномальному повышению амплитуд вейвлет-коэффициентов в узлах ПОД, нарушая

естественный характер их затухания [138]. Это различие позволяет использовать ПОД как базовую единицу анализа при фильтрации: вместо обработки отдельных коэффициентов на каждом уровне декомпозиции (в каждой субполосе) алгоритм оценивает «значимость» всего ПОД на основе совместной статистики его узлов. Такой подход повышает надёжность выделения сигнала на фоне шума и способствует сохранению структурных особенностей изображения при подавлении спекл-шума.

3.2 Алгоритм обработки ПОД вейвлет-преобразования с использованием архитектуры рекуррентной нейронной сети LSTM

В контексте обработки вейвлет-коэффициентов искаженного изображения структура ПОД, представленная в виде упорядоченной последовательности, может служить входным сигналом для рекуррентной нейронной сети LSTM (RNN-LSTM). Это позволяет модели выявлять зависимости между родительскими и дочерними коэффициентами и оценивать их значимость в условиях шума [63, 93–97, 138].

3.2.1 Архитектура RNN-LSTM для обработки ПОД

Ниже представлено описание архитектуры нейронной сети LSTM, применяемой для обработки ПОД, цитируемое из работы [138].

«Разрабатывается параллельная 3-канальная архитектура RNN-LSTM, в которой каждый канал (горизонтальный, вертикальный, диагональный) содержит собственную RNN-LSTM сеть, настроенную на обработку ПОД своего направления. Входной слой каждого канала принимает последовательность вейвлет-коэффициентов, извлечённых из ПОД соответствующего направления. Скрытые LSTM-слои в каждом канале обрабатывают входную последовательность с учётом пространственной зависимости и контекста предыдущих коэффициентов в своём направлении. Выходной слой каждого канала генерирует оценки вейвлет-коэффициентов для соответствующего направления. В качестве функции активации выходного слоя используется линейная функция активации [94].»

3.2.2 Алгоритм обработки ПОД с использованием RNN-LSTM

Предлагаемый алгоритм включает следующие шаги:

1. Формирование ПОД. К зашумлённым изображениям применяется дискретное двумерное вейвлет-преобразование, в результате которого формируются субполосы вейвлет-коэффициентов в разных направлениях (горизонтальном, вертикальном, диагональном) и разных уровнях разложения. Для каждого направления отдельно формируются векторы ПОД, отражающие локальные структуры и зависимости в соответствующей субполосе.

2. Обучение трёхканальной сети. Формируется обучающий набор данных: на основе пар "неискажённое изображение — зашумлённое изображение" формируются соответствующие пары последовательностей ПОД

Трёхканальная сеть RNN-LSTM обучается параллельно: каждый канал получает на вход зашумлённые коэффициенты своего направления и обучается предсказывать (вычислять) соответствующие оценки вейвлет-коэффициентов.

Для обучения трёхканальной архитектуры SOT-LSTM применяется иерархическая функция потерь, основанная на среднеквадратичной ошибке, которая учитывает многоуровневую структуру ПОД. Поскольку каждый ПОД состоит из вейвлет-коэффициентов разных уровней разложения, ошибка оценивания вейвлет-коэффициентов взвешивается с учётом значимости каждого уровня. Кратно масштабное вейвлет-разложение локализует спекл-шум преимущественно в высокочастотных (мелкомасштабных) субполосах. Вместе с тем, такие субполосы также содержат важные структурные элементы изображения, как контуры объектов, текстуры и другие мелкие детали. Восприятие визуального качества результирующего изображения в значительной степени определяется точностью оценивания именно вейвлет-коэффициентов данных субполос. Тогда при построении функции потерь применяется взвешенный подход: ошибке оценивания коэффициентов на нижнем уровне разложения присваивается больший вес, чем ошибке оценивания коэффициентов на более высоких уровнях разложения, которые значительно менее подвержены влиянию шума. Общая функция потерь рассчитывается как среднее

арифметическое по трём каналам. Оптимизация весов сети осуществляется с помощью алгоритма Adam, направленного на минимизацию общей функции потерь по всем трём каналам.

3. Шумоподавление с использованием обученной сети.

– К зашумлённому изображению применяется дискретное двумерное вейвлет-преобразование. Для каждого направления независимо формируются ПОД.

– Сформированные ПОД подаются на вход соответствующих каналов обученной сети.

– Каждый канал сети генерирует оценки восстановленных вейвлет-коэффициентов для своего направления.

4. Выполнить обратное преобразование полученного множества ПОД в массив вейвлет-коэффициентов.

5. Выполнить обратное вейвлет-преобразование нового массива вейвлет-коэффициентов, получив оценку неискаженного изображения.

Обработка ПОД рекуррентной сетью LSTM имеет временную сложность $O(N^2 \cdot d_L^2)$ и пространственную сложность $O(N^2 + P_L)$, где d_L — размерность скрытого состояния, P_L — число обучаемых параметров трёхканальной LSTM.

3.2.3 Результаты моделирования

Для оценки эффективности предложенного алгоритма были проведены эксперименты, в рамках которых использовались базы изображений TAMPERE17 и USC-SIPI. Сравнение проводилось с методами, применяемыми для обработки изображений: фильтр Ли, метод вейвлет-фильтрация BayesShrink. Реализация предложенной архитектуры SOT-LSTM выполнена на языке Python с использованием фреймворка PyTorch версии 2.5. Вейвлет-разложение и реконструкция осуществлялись с помощью PyWavelets с биортогональным вейвлетом с симметричными фильтрами bio4.4, что обеспечивает линейную фазу и отсутствие артефактов при реконструкции. Каждое изображение 512×512 подвергалось разложению на три уровня, формируя ПОД для трёх ориентаций, которые затем кодировались в последовательности токенов длиной 21. На основе этих последовательностей был сформирован датасет, включающий пары:

зашумлённые (входные) и соответствующие им целевые последовательности для каждой ориентации.

Набор данных для обучения модели сформирован на основе 10 изображений, отобранных из исходной базы данных, к которым был добавлен спекл-шум различной интенсивности. Для оценки и сравнительного анализа эффективности модели использовался независимый тестовый набор, включающий 10 других изображений из той же баз данных. Итоговый результат экспериментальных исследований определяется как среднее значение метрик, полученных при обработке всех 10 тестовых изображений.

Результаты оценки эффективности шумоподавления предложенного алгоритма представлены в табл. 3.1 и на рис. 3.2, рис. 3.3.

Таблица 3.1 – Результаты экспериментов

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		Фильтр Ли	BayesShrink	SOT-LSTM
ПОСШ				
0,02	22,2	25,3	25,8	26,7
0,04	19,5	23,5	24,2	24,9
0,06	17,5	22,2	23,0	23,7
0,08	16,3	21,4	22,0	22,9
0,10	15,8	20,8	21,6	22,1
SSIM				
0,02	0,59	0,69	0,71	0,73
0,04	0,47	0,61	0,64	0,68
0,06	0,38	0,56	0,59	0,63
0,08	0,33	0,52	0,55	0,59
0,10	0,29	0,50	0,52	0,56
MS-SSIM				
0,02	0,83	0,90	0,91	0,92
0,04	0,76	0,85	0,87	0,89
0,06	0,70	0,81	0,83	0,86
0,08	0,66	0,79	0,81	0,83
0,10	0,64	0,78	0,79	0,81
GMSD				
0,02	0,042	0,038	0,035	0,032
0,04	0,066	0,045	0,042	0,039
0,06	0,087	0,049	0,046	0,043
0,08	0,101	0,053	0,050	0,046
0,10	0,113	0,057	0,052	0,048




Рисунок 3.2 – Зависимость ПОСШ от дисперсии шума

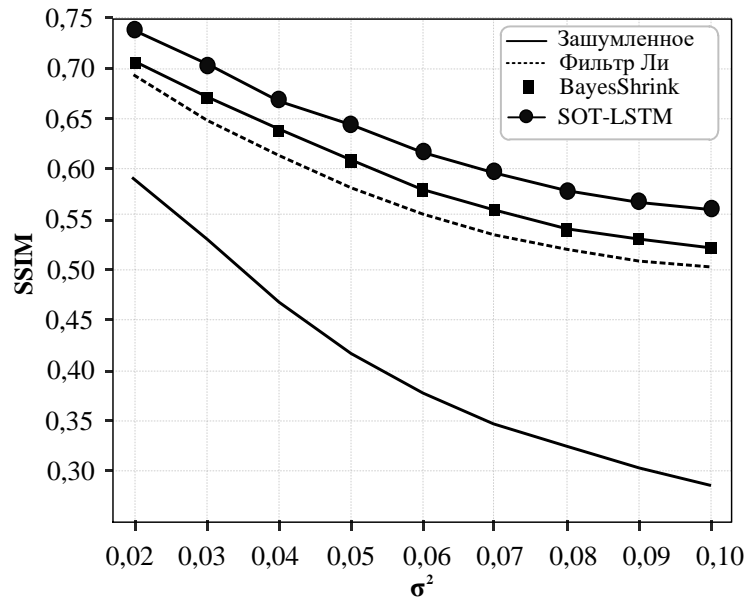


Рисунок 3.3 – Зависимость SSIM от дисперсии шума

Анализ данных, представленных в табл. 3.1, а также на рис. 3.2 и рис. 3.3, видно, что предложенный алгоритм показал лучшие значения по используемым метрикам ПОСШ, SSIM, MS-SSIM и GMSD.

3.3 Алгоритм обработки ПОД вейвлет-преобразования с использованием архитектуры нейронной сети трансформера

3.3.1 Архитектура трансформера для обработки ПОД

Архитектура нейронной сети трансформера представляет собой модификацию нейронной сети, изначально разработанной для обработки последовательных данных. В отличие от рекуррентных и свёрточных сетей такая

модель основана на механизме “самовнимания” (self-attention), обеспечивающем прямое моделирование зависимостей между всеми парами элементов последовательности. В результате появляется возможность одновременно учитывать как локальный, так и глобальный контекст без рекуррентных связей. Классическая архитектура трансформера состоит из: двух основных частей — кодировщика и декодировщика, каждый из которых представляет собой стек из N идентичных слоёв [98-103]. Для решения задачи обработки ПОД предлагается использовать модифицированную архитектуру трансформера, состоящую только из кодировщика. Приведённое далее описание предлагаемой архитектуры взято из работы [139].

«В отличие от классической модели трансформера данная архитектура адаптирована для последовательной регрессии. В этом случае входом является последовательность вейвлет-коэффициентов зашумленного изображения, а выходом — их оценки, обеспечивающие шумоподавление.

Предлагаемая модель, обозначаемая как SOT_TRANS и схематически представленная на рис. 3.4, состоит из следующих ключевых компонентов.

1. Входное линейное проецирование: каждый скалярный вейвлет-коэффициент преобразуется в векторное представление.

2. Иерархическое позиционное кодирование: поскольку механизм самовнимания в архитектуре трансформера изначально инвариантен к порядку входных элементов, для корректного учёта иерархической структуры ПОД применяется иерархическое позиционное кодирование. Это кодирование объединяет две комплементарные компоненты: уровневый эмбединг и порядковое синусоидальное кодирование. Уровневый эмбединг представляет собой дискретное векторное отображение, явно кодирующее масштабный уровень (глубину декомпозиции) каждого коэффициента в дереве, что позволяет модели различать грубые и детальные масштабы вейвлет-разложения. Порядковое синусоидальное кодирование, в свою очередь, сохраняет информацию о позиции коэффициента относительно других коэффициентов на том же уровне, отражая их

локальный пространственный порядок с помощью непрерывных синусоидальных функций.

3. Кодировщик: для каждого из трёх каналов, соответствующих ориентации (H, V, D), в архитектуре используются три независимых, но структурно идентичных кодировщика. Каждый из них включает многоголовочный механизм внимания (Multi-Head Attention Mechanism) с 4 головами и скрытой размерностью 64. За блоком механизма внимания следует полносвязная сеть, выполняющая нелинейное преобразование полученных представлений. Остаточные связи (сложение) и нормализация применяются перед каждым подблоком, что способствует повышению стабильности обучения.

4. Межканальный агрегатор: после независимой обработки каждого ориентационного канала их признаковые представления объединяются в единый тензор, формируя обобщённое мультимодальное описание вейвлет-коэффициентов на данном масштабе. Далее применяется специализированный модуль — межканальный агрегатор, реализованный в виде единого многоголовочного механизма внимания, который оперирует по всем позициям объединённого тензора. Этот механизм позволяет коэффициентам из разных ориентационных каналов обмениваться контекстной информацией и устанавливать кросс-ориентационные зависимости. Результирующее агрегированное представление затем разделяется обратно на три канала, соответствующих исходным ориентациям, причём к каждому из них применяется остаточная связь и нормализация. Такая схема обеспечивает как специализированную обработку внутриканальных особенностей, так и эффективный межканальный синтез информации, что в совокупности повышает качество фильтрации.

5. Выходной регрессионный слой: каждый канал проходит через собственный выходной слой, реализованный в виде отдельного линейного преобразования. В результате для каждого канала формируется обновлённая последовательность.»

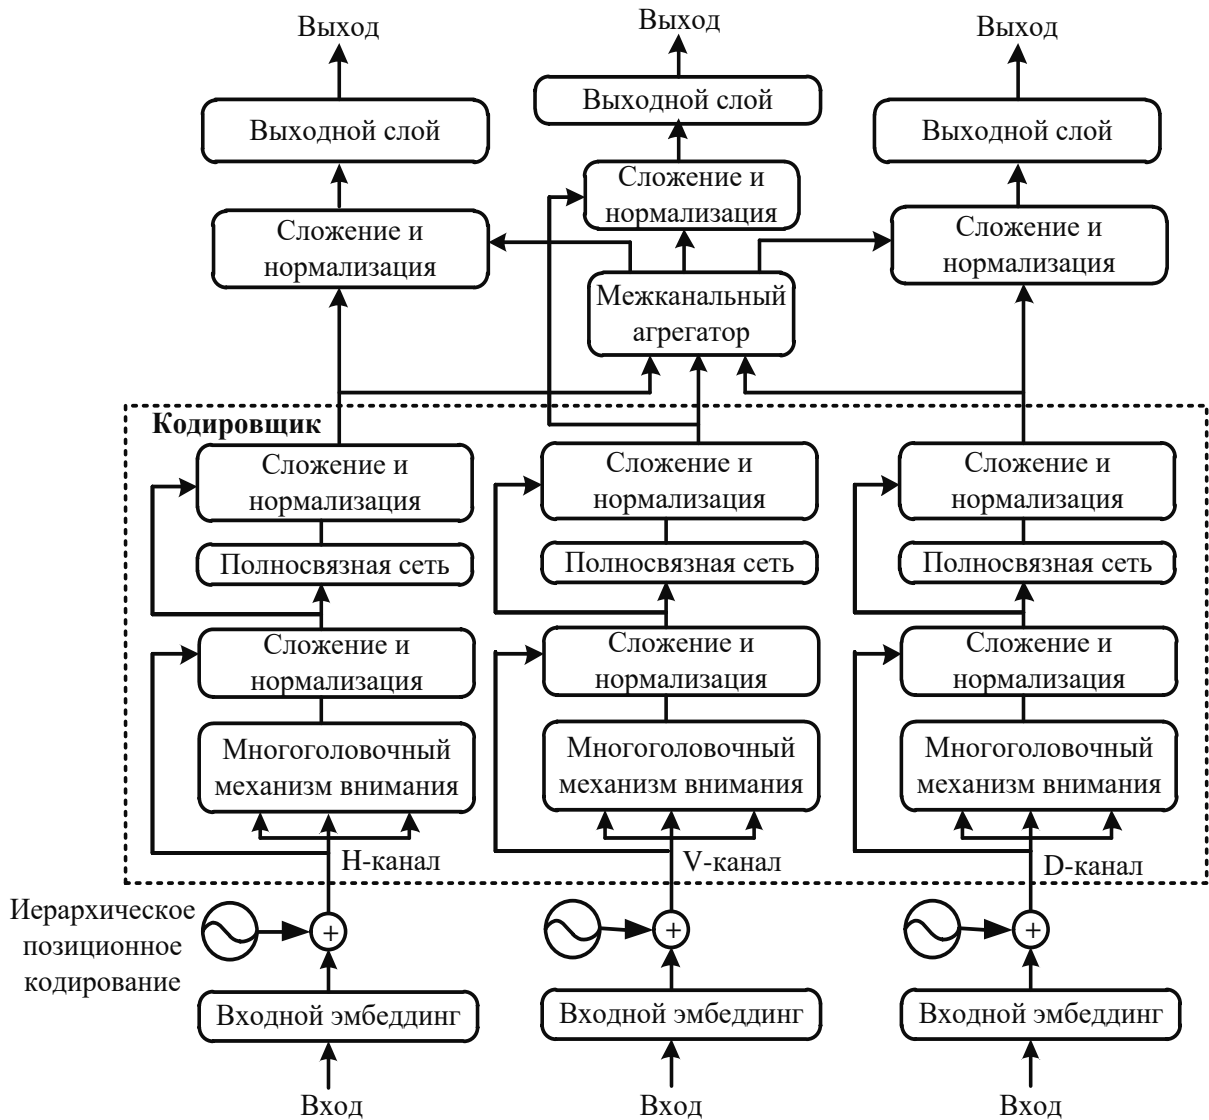


Рисунок 3.4 – Предлагаемая модель трансформера SOT_TRANS

Для обучения модели используется иерархическая функция потерь, аналогичная применявшейся при обучении SOT-LSTM (см. раздел 3.2.2).

Для упрощения задачи обучения применяется метод остаточного обучения: модель обучается предсказывать шумовую составляющую в зашумленных вейвлет-коэффициентах, а не “чистые” коэффициенты. Такой метод существенно упрощает задачу обучения, снижает сложность целевой функции и способствует более стабильной и быстрой сходимости процесса оптимизации. Обучение модели осуществляется с использованием оптимизатора Adam с начальной скоростью обучения 10^{-4} . Модель обучается в течение 25 эпох при размере батча, равном 256. По завершении обучения параметры модели сохраняются и в дальнейшем используются для обработки ПОД зашумлённых изображений.

3.3.2 Алгоритм обработки ПОД с использованием трансформера

Предлагаемый метод обработки ПОД состоит из следующих шагов [139].

Шаг 1. Вейвлет-декомпозиция: к изображению применяется L -уровневое ДВП с выбранным вейвлет-базисом. В результате получается одна низкочастотная субполоса A_L и высокочастотные субполосы $(H_1, V_1, D_1, \dots, H_L, V_L, D_L)$.

Шаг 2. Формирование ПОД вейвлет-коэффициентов субполос деталей в каждой ориентации H, V, D .

Шаг 3. Представление ПОД для трансформера: осуществляется путём упорядочивания всех вейвлет-коэффициентов, извлечённых из каждого ПОД в фиксированную последовательность.

Шаг 4. Обработка ПОД с использованием трансформера: последовательности вейвлет-коэффициентов, полученные на шаге 3, подаются на вход трансформера в виде одномерного временного ряда скалярных значений. Сеть предсказывает последовательность оценок вейвлет-коэффициентов.

Шаг 5. Реконструкция субполос деталей из предсказанных вейвлет-коэффициентов.

Шаг 6. Формирование оценки оригинала изображения: полученные субполосы деталей объединяются с низкочастотной субполосой A_L , после чего применяется обратное вейвлет-преобразование. В результате формируется оценка оригинала изображения.

Механизм самовнимания в архитектуре трансформера вносит квадратичную зависимость от длины последовательности ПОД, что даёт временную сложность $O(N^2 4^L d_T)$ и пространственную сложность $O(N^2 + P_T)$, где L – уровень декомпозиции, d_T – размерность эмбединга, P_T – параметры трансформера.

3.3.3 Результаты моделирования

Условия моделирования и оценки эффективности предложенного метода полностью соответствуют условиям, описанным для SOT_LSTM в разделе 3.2.3. Реализация архитектуры SOT_TRANS выполнена на Python с использованием

фреймворка PyTorch (версия 2.5) и стандартных модулей, обеспечивающих поддержку механизма многоголового внимания и обучаемых эмбеддингов.

Экспериментальные результаты приведены в табл. 3.2. Для наглядного сравнения на рис. 3.5 и 3.6 представлены графики зависимости значений метрик качества от уровня шума.

Таблица 3.2 – Результаты экспериментов

Дисперсия шума	Зашумлённое изображение	Восстановленное изображение		
		Фильтр Ли	BayesShrink	SOT-TRANS
ПОСШ				
0,02	22,3	25,4	25,9	27,1
0,04	19,6	23,6	24,4	25,4
0,06	17,8	22,3	23,1	24,1
0,08	16,7	21,5	22,3	23,2
0,10	15,9	20,9	21,7	22,5
SSIM				
0,02	0,58	0,69	0,72	0,74
0,04	0,46	0,62	0,65	0,68
0,06	0,38	0,57	0,59	0,65
0,08	0,35	0,52	0,56	0,62
0,10	0,32	0,51	0,53	0,60
MS-SSIM				
0,02	0,83	0,90	0,91	0,92
0,04	0,76	0,85	0,87	0,89
0,06	0,70	0,81	0,83	0,86
0,08	0,67	0,79	0,81	0,85
0,10	0,64	0,78	0,79	0,83
GMSD				
0,02	0,042	0,038	0,035	0,031
0,04	0,066	0,045	0,042	0,039
0,06	0,087	0,049	0,046	0,043
0,08	0,101	0,053	0,050	0,046
0,10	0,113	0,057	0,052	0,048




Рисунок 3.5 – Зависимость ПOCШ от дисперсии шума

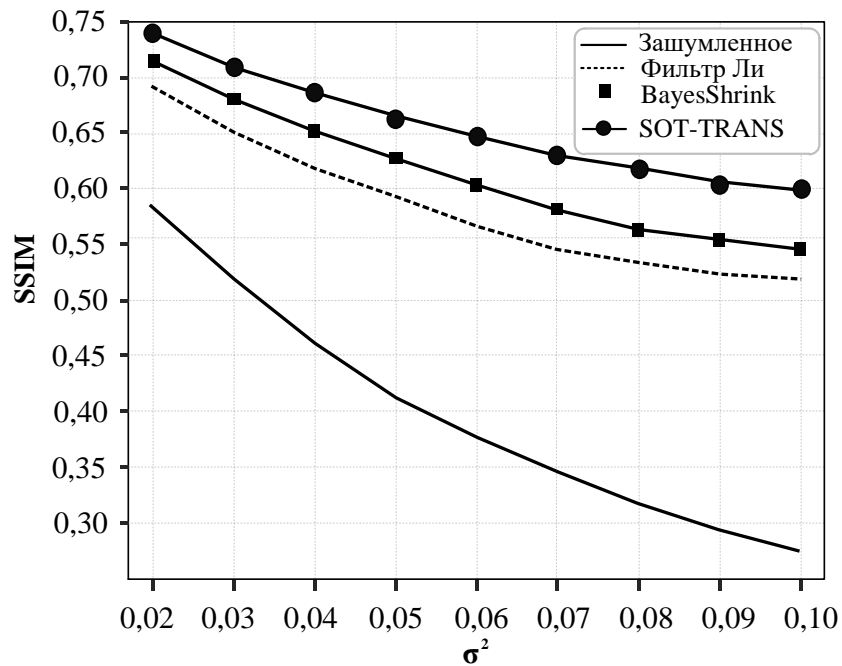


Рисунок 3.6 – Зависимость SSIM от дисперсии шума

Данные табл. 3.2 и графики на рис. 3.5 и 3.6 демонстрируют, что предложенный алгоритм показал лучшие средние значения по всем использованным метрикам (ПOCШ, SSIM, MS-SSIM и GMSD) в рамках проведённой экспериментальной постановки.

На рис. 3.7 показаны экспериментальные результаты обработки одного из тестовых изображений с дисперсией шума 0,05. Рис. 3.7, а демонстрирует зашумленное изображение. Рис. 3.7 б, в, г отображают результаты

3.7, г) демонстрирует превосходящую эффективность по совокупности критериев: достигается значительное снижение уровня шума при одновременном сохранении пространственной резкости объектов, отсутствуют визуально заметные артефакты, а также обеспечивается корректное восстановление яркостных характеристик фона.

Несмотря на относительно высокую эффективность алгоритмов анализа и фильтрации зашумлённых изображений на основе обработки ПОД, они имеют ряд ограничений, которые следует учитывать при практическом применении. Во-первых, хотя архитектуры масштабируема, обработка изображений размером значительно больше 512×512 (например, 2048×2048) требует либо разбиения на тайлы, либо увеличения объёма памяти, что может привести к появлению стыковочных артефактов на границах фрагментов, особенно в текстурных областях. Во-вторых, для обучения модели необходимо наличие пар «искажённое изображение – неискажённое изображение», которые не всегда доступны в реальных условиях, особенно в случае PCA-изображений. В-третьих, несмотря на то, что архитектуры учитывают взаимосвязи между коэффициентами внутри ПОД и корреляцию между ориентациями, восстановление геометрических отношений между коэффициентами осуществляется косвенно, за счёт позиционного кодирования, а не через явную локальную пространственную структуру, характерную для свёрточных сетей.

3.4 Выводы по третьей главе

В третьей главе разработаны и исследованы алгоритмы анализа и фильтрации зашумлённых изображений на основе обработки ПОД вейвлет-преобразования с использованием архитектур RNN-LSTM и трансформера.

1. Показано, что ПОД вейвлет-преобразования являются информативной формой представления изображения, позволяющей учитывать межмасштабные связи между коэффициентами. Использование такого представления создаёт основу для построения эффективных алгоритмов анализа и фильтрации изображений, искажённых шумом.

2. Разработан и исследован алгоритм обработки ПОД вейвлет-преобразования с использованием архитектуры RNN-LSTM, ориентированный на моделирование зависимостей между коэффициентами, принадлежащими одной древовидной структуре. Установлено, что применение RNN-LSTM к последовательностям коэффициентов ПОД позволяет повысить качество восстановления изображения по сравнению с другими методами фильтрации, что подтверждается результатами проведённых вычислительных экспериментов.

3. Разработан и исследован алгоритм обработки ПОД вейвлет-преобразования на основе архитектуры трансформера, использующий механизм самовнимания для анализа взаимосвязей между коэффициентами в пределах ПОД. Показано, что применение архитектуры трансформера обеспечивает повышение качества восстановления изображений как по объективным метрикам качества, так и по результатам субъективной визуальной оценки.

ГЛАВА 4. ПРОГРАММНАЯ РЕАЛИЗАЦИЯ РАЗРАБОТАННЫХ АЛГОРИТМОВ

4.1 Развитие программного комплекса IMPROC

Программный комплекс IMPROC был разработан в ходе диссертационных исследований, выполненных аспирантами под научным руководством доктора технических наук, профессора Ю. С. Бехтина. Каждая версия, от 1.0 до 3.0, основана на результатах конкретных исследований и отражает обширное развитие теории и алгоритмов в области цифровой обработки изображений, а также расширение её практического применения: от специализированного инструмента для специалистов до универсальной платформы, интегрирующей учебные, исследовательские и прикладные функции [129–139]. Эта эволюция обусловлена не только достижениями в методах обработки изображений, но и возрастающими требованиями к доступности, гибкости и совместимости с современными вычислительными технологиями, включая машинное обучение и аппаратную реализацию на программируемых логических интегральных схемах (ПЛИС).

4.1.1 *Первая версия программного комплекса IMPROC 1.0*

Первая версия комплекса IMPROC 1.0, разработанная на языке C++, была ориентирована преимущественно на специалистов в области обработки радиолокационных изображений (РЛИ). Основу её алгоритмической базы составляли классические методы фильтрации (медианный фильтр, фильтр Винера, фильтры Ли и Фроста), а также вейвлет-метод фильтрации VisuShrink и три оригинальных алгоритма текстурно-зависимой обработки, предложенных на кафедре АИТУ РГРТУ под руководством профессора Ю. С. Бехтина. Комплекс поддерживал выбор вейвлетов (sym4, coif3, db4 и др.), настройку числа уровней декомпозиции, правила пороговой обработки (soft/hard thresholding) и методов продолжения границ изображения (симметрия, добавление нулей и т.п.) для устранения краевых эффектов.

Ключевой особенностью IMPROC 1.0 была относительно полная интеграция доступных на тот момент методов шумоподавления и сжатия. Кроме

того, программное обеспечение позволяло моделировать как аддитивный, так и мультипликативный шум с различными законами распределения (равномерный, гауссовский и экспоненциальный). Однако первая версия комплекса IMPROC 1.0 обладает некоторыми существенными ограничениями. Во-первых, его интерфейс был относительно сложным для понимания и ориентирован на пользователей с большим опытом обработки изображений. Во-вторых, в нем отсутствуют удобные инструменты для визуального анализа и сравнения методов. Это ограничивало его использование в обучении, особенно при проведении практических экспериментов со студентами.

4.1.2 *Вторая версия программного комплекса IMPROC 2.0*

Вторая версия IMPROC 2.0 была разработана с целью преодоления недостатков первой версии путем создания более удобного графического интерфейса на основе библиотек GTK+ и GLIB, а также расширения её функциональности. Комплекс IMPROC 2.0 поддерживает загрузку нескольких изображений, позволяет работать с областями интереса и вычисляет коэффициенты вариации как в пространственной, так и в вейвлет-областях. В этой версии набор методов вейвлет-преобразования расширен и включает как дискретные, так и пакетные вейвлет-преобразования, а также добавлены несколько типов вейвлетов, включая bior 4.4 и CDF 9/7.

Комплекс отличается интуитивно понятным графическим интерфейсом и обеспечивает стабильную работу под управлением операционных систем Windows XP, Windows 7 (32 и 64 bit), Windows 8.1 (64 bit). Особое внимание было уделено интеграции с аппаратными средствами: IMPROC 2.0 позволяет генерировать HDL-код на языке Verilog на основе заданного плана эксперимента, что обеспечивает возможность реализации разработанных алгоритмов на ПЛИС семейства Xilinx Virtex-7. Эта функциональность расширяет применение комплекса в учебном процессе, а также в лабораторных практикумах. Однако архитектура IMPROC 2.0 тесно связана с экосистемой C/GTK/Gnuplot/ImageMagick, что ограничивает кроссплатформенную поддержку, требует множества специфических зависимостей и препятствует интеграции с

современными методами машинного обучения. Существенным недостатком является отсутствие поддержки алгоритмов нейронных сетей, широко используемых сегодня в обработке изображений.

4.1.3 Обоснование необходимости перехода к IMPROC 3.0

С учётом выявленных недостатков предшествующих версий программного комплекса, новых результатов научных исследований, накопленного практического опыта, а также прогресса в области вычислительных технологий и обработки изображений, возникла необходимость в разработке новой версии программного комплекса — IMPROC 3.0. Данная версия была полностью перепроектирована и реализована на языке программирования Python. Такой выбор обусловлен следующими ключевыми факторами:

Кроссплатформенность и доступность: Python обладает широким распространением в научной и учебной среде, поддерживает работу на всех основных ОС без дополнительных зависимостей.

Модульность и расширяемость: архитектура на основе Python-пакетов (NumPy, SciPy, scikit-image, PyWavelets, OpenCV, TensorFlow/PyTorch) позволяет легко подключать как традиционные, так и современные методы обработки изображений.

Интеграция глубокого обучения: Python является де-факто стандартом в области машинного обучения, что позволило впервые включить в состав IMPROC методы шумоподавления с использованием нейронной сети, такие как U-Net и DnCNN, обученные на синтетических парах «зашумлённое–неискажённое» изображение.

Многорежимная функциональность: новая версия обеспечивает использование комплекса как в учебном процессе (понятный графический пользовательский интерфейс (GUI), пошаговые инструкции по применению алгоритмов, визуализация промежуточных результатов), так и в научно-исследовательской деятельности (экспериментальный режим, предназначенный для сравнения эффективности методов с автоматическим расчётом метрик

качества СКО, ПОСШ и SSIM и др., и визуально отображает результаты экспериментов).

Гибкость интерфейса: использование PySide6/Qt позволяет создать современный, адаптивный и интуитивно понятный интерфейс, разделённый на функциональные области, что значительно упрощает работу как студентов, так и исследователей.

Таким образом, переход к IMPROC 3.0 представляет собой объективную необходимость в рамках непрерывного совершенствования программного комплекса, поскольку он интегрирует методологические и алгоритмические наработки предыдущих версий с современными вычислительными моделями и методами, обеспечивая его актуальность и применимость как в учебном процессе, так и в научных исследованиях.

4.2 Общая архитектура программного комплекса IMPROC 3.0

Программный комплекс IMPROC 3.0 представляет собой полностью переработанную, современную реализацию, разработанную на языке Python и ориентированную как на учебные, так и на научно-исследовательские задачи в области обработки изображений, включая радиолокационные (РЛИ). Архитектура комплекса построена на современных инструментах проектирования программного обеспечения: она является модульной, расширяемой, кроссплатформенной и поддерживает интеграцию как традиционных, так и нейросетевых методов обработки.

IMPROC 3.0 реализован с использованием ведущих научных и компьютерных библиотек экосистемы Python:

NumPy и SciPy обеспечивают эффективную работу с многомерными массивами и выполнение математических операций;

scikit-image предоставляет реализации классических методов обработки изображений (медианная фильтрация, выделение контуров, морфологические преобразования и др.);

PyWavelets используется для выполнения вейвлет-преобразования с поддержкой множества различных семейств вейвлетов (haar, db, sym, coif, bior и т. д.);

OpenCV применяется для базовых операций с изображениями (поворот, обрезка, преобразование цветного изображения в градациях серого, аффинные преобразования) [145];

TensorFlow / PyTorch служат основой для интеграции глубоких нейронных сетей, таких как U-Net, DnCNN и другие модели, обученные для задач обработки изображений.

Такая модульная организация позволяет легко заменять или дополнять компоненты без вмешательства в ядро приложения, а также упрощает поддержку и сопровождение кодовой базы.

IMPROC 3.0 предлагает два режима функционирования: режим обработки изображения и экспериментальный режим, что обеспечивает гибкость при решении учебных и исследовательских задач.

Режим обработки изображения предназначен для пошагового применения различных методов обработки к изображению. Пользователь может выполнить широкий спектр операций: от базовых (поворот, обрезка, преобразование в оттенки серого и т. д.) до сложных (фильтрация шума, сегментация, текстурный анализ, выделение контуров и т. д.). Режим поддерживает визуальное сравнение исходного и обработанного изображений, анализ вейвлет-коэффициентов и экспорт результатов обработки.

Экспериментальный режим ориентирован на научные исследования и сравнительный анализ алгоритмов. Пользователь может загрузить набор тестовых изображений, задать диапазон интенсивности шума (аддитивного гауссовского, мультипликативного и др.), выбрать набор методов (включая базовые классические, авторские и методы на основе нейронных сетей) и автоматически запустить пакетную обработку. По завершении эксперимента программа рассчитывает объективные метрики качества и отображает их в виде таблиц и

графиков. Все результаты могут быть сохранены в структурированном виде для последующего анализа.

Одной из ключевых архитектурных особенностей IMPROC 3.0 является наличие единого интерфейса (API) для подключения любого метода обработки, включая классические методы (например, фильтры Ли, Куана, Фроста и т. д.), вейвлет-методы (например, VisuShrink, SureShrink и т. д.) или модели нейронных сетей. Каждый метод реализуется как отдельный модуль. Такой подход обеспечивает единообразие подключения методов, упрощает расширение функциональности и позволяет включать в сравнительный анализ как известные, так и авторские разработки, выполненные в рамках диссертационного исследования.

IMPROC 3.0 разработан с расчётом на работу в современных операционных системах: Windows, macOS, Linux. Благодаря использованию кроссплатформенных библиотек Python и графического интерфейса на основе PySide6/Qt, интерфейс программного комплекса хорошо функционирует на всех поддерживаемых платформах без необходимости перекомпиляции или установки специфических зависимостей. Кроме того, программный комплекс совместим с облачными и удалёнными вычислительными средами, включая Google Colab и Jupyter Notebook, что способствует расширению его использования в дистанционном обучении и при выполнении совместных исследований.

Таким образом, архитектура IMPROC 3.0 сочетает научную строгость, технологическую гибкость и простоту использования, обеспечивая универсальную платформу для решения актуальных задач обработки изображений в учебной и исследовательской практике.

4.3 Режимы функционирования программного комплекса IMPROC 3.0

4.3.1 Режим обработки зашумленного изображения

Режим обработки изображения в программном комплексе IMPROC 3.0 представляет собой основной интерфейс для выполнения широкого спектра операций над изображением. Он разработан с учётом как учебных задач — для

демонстрации принципов работы алгоритмов обработки, так и практических целей — получения обработанных изображений для конкретных задач с использованием различных методов. Все функции интегрированы в единый рабочий процесс и поддерживают визуальное сравнение исходного, зашумлённого (при его наличии) и обработанного изображений в реальном времени.

Комплекс поддерживает загрузку изображения в наиболее распространённых графических форматах, включая png, jpeg, bmp, tiff и raw, с автоматическим приведением к внутреннему представлению (NumPy-массив с плавающей точкой). После обработки результат может быть сохранён в том же или ином формате с настраиваемым качеством (в случае сжатия jpeg) или без потерь (в форматах png, tiff), что обеспечивает гибкость при подготовке данных для публикаций, отчётов или последующей обработки.

Перед применением основных алгоритмов пользователь может выполнить ряд базовых операций предварительной обработки: поворот изображения на произвольный угол (с интерполяцией); обрезка области интереса; зеркальное отражение по горизонтали/вертикали; преобразование цветных изображений в градации серого; нормализация яркости и гамма-коррекция. Эти функции реализованы с использованием библиотек OpenCV и scikit-image, обеспечивающих высокую точность и скорость выполнения.

Центральной возможностью режима является фильтрация спекл-шума, объединяющая классические методы (усредняющий, медианный фильтр, фильтр Гаусса, Винера, Ли, Фроста, Куана, NLM), методы, основанные на вейвлет-преобразовании, и методы нейронных сетей (U-Net, DnCNN), а также собственные алгоритмы, разработанные на кафедре АИТУ Рязанского государственного радиотехнического университета под руководством профессора Ю.С. Бехтина.

- Алгоритм I — поиск одного, глобального порога для вейвлет-коэффициентов, минимизирующего суммарную СКО для зашумленных и неискаженных точек изображения.

- Алгоритм II — поиск оптимальных пороговых значений в пределах каждого частотного поддиапазона при вейвлет-преобразовании.
- Алгоритм III — анализ иерархической структуры вейвлет-дерева с удалением ветвей, доминирующих по шумовой энергии.
- Модифицированный алгоритм пороговой обработки вейвлет-коэффициентов с усиление НЧК.
- Адаптивный алгоритм вейвлет-фильтрации спекл-шума, основанный на локальной оценке статистических характеристик шума.
- Wavelet_UNet — обработка вейвлет-коэффициентов с использованием нейронной сети U-Net.
- SOT_TRANS — обработка ПОД вейвлет-коэффициентов на основе архитектуры трансформера.
- SOT_LSTM — обработка ПОД вейвлет-коэффициентов с использованием RNN-LSTM.

Сжатие изображений может осуществляться с использованием следующих методов: методы сжатия без потерь (EZW, SPIHT), методы сжатия с потерями (JPEG, JPEG 2000, WebP), а также модифицированный алгоритм SPIHT, разработанный для обработки и сжатия зашумленных изображений.

Для решения задач выделения контуров предусмотрены:

- классические методы выделения контуров: операторы Sobel, Canny, Laplacian of Gaussian, Prewitt, Roberts;
- метод на основе вейвлет-преобразования для выделения контуров в разных масштабах.

Кроме того, в режиме обработки доступны инструменты для анализа неоднородности изображения: классификация текстур на основе локальных статистик и построение карты однородности изображения. Этот процесс может быть выполнен непосредственно на исходном изображении или на основе результатов вейвлет-преобразования.

Все операции сопровождаются интерактивными визуальными представлениями как в пиксельной, так и в вейвлет-уровнях, а также возможностью сохранения результатов обработки.

Таким образом, режим обработки изображения в IMPROC 3.0 объединяет в себе полный процесс цифровой обработки изображений, от первичной загрузки до анализа и сохранения результата, обеспечивая как наглядность для учебных целей, так и глубину анализа для научных исследований.

4.3.2 Экспериментальный режим

Экспериментальный режим программного комплекса IMPROC 3.0 предназначен для проведения систематических научных исследований по сравнительному анализу эффективности известных и авторских методов обработки зашумлённых изображений, включая методы и алгоритмы, разработанные в рамках диссертационного исследования.

Пользователь может одновременно загрузить набор тестовых изображений, включающий как стандартные эталонные изображения (например, Lena, Barbara, Cameraman), так и изображения, характерные для радиолокационной съёмки (РЛИ). IMPROC 3.0 поддерживает работу с изображениями в форматах png, jpeg, bmp, tiff, в том числе в оттенках серого и многоканальными (цветные изображения автоматически конвертируются при необходимости). Загруженные изображения отображаются списком, для которых можно установить параметры шумового воздействия в соответствии с глобальными настройками.

Для моделирования реальных условий зашумления комплекс поддерживает следующие типы шума: аддитивный гауссовский шум с задаваемым математическим ожиданием и дисперсией; мультипликативный шум (спекл-шум), характерный для РЛИ, с настраиваемой дисперсией, а также другие типы шумов.

Генерация шума выполняется с использованием генераторов псевдослучайных чисел, обеспечивая статистическую корректность и воспроизводимость.

Диапазон уровня шума задаётся пользователем. Для каждого значения в этом диапазоне система автоматически добавляет шум к каждому изображению из

набора. Это позволяет оценить устойчивость алгоритмов к изменению уровня шума и выявить диапазон их эффективности.

Программный комплекс предоставляет пользователям возможность одновременно выбирать до пяти методов для сравнительного анализа, включающих три независимых метода (M1, M2, M3) и два комбинированных метода фильтрации (K1 и K2). Комбинированный метод K1 реализует схему последовательного применения фильтров: сначала ко всему изображению применяется фильтр 1, после чего к полученному результату применяется фильтр 2. Второй комбинированный метод K2 основан на предварительном текстурном анализе с целью идентификации однородных и неоднородных областей изображения. После чего фильтр 1 применяется к однородным областям, а фильтр 2 — к неоднородным.

Комплекс автоматически применяет каждый выбранный метод ко всем изображениям и всем уровням шума в заданном диапазоне, обеспечивая полный факторный эксперимент без ручного вмешательства. Для объективной оценки эффективности методов система рассчитывает такие метрики, как СКО, ПОСШ и SSIM [147, 148]. Все метрики вычисляются автоматически на основе сравнения обработанного изображения с исходным (чистым) эталоном, что возможно благодаря контролируемой генерации шума.

Результаты эксперимента представляются и сохраняются в табличном и графическом видах. Табличные данные сохраняются в форматах CSV/Excel и содержат средние значения метрик для всех изображений при различных уровнях шума и применяемых алгоритмах. Графики иллюстрируют динамику изменения метрик в зависимости от уровня шума.

Для обеспечения полноты и детализации информации все параметры эксперимента сохраняются в конфигурационном файле, включающем: список изображений; тип и диапазон шума; список алгоритмов и их параметры (тип вейвлета, уровень декомпозиции, правила пороговой обработки и т.д.); дата проведения эксперимента. Такая конфигурация особенно важна при публикации результатов и сравнении с работами других исследователей.

Таким образом, экспериментальный режим IMPROC 3.0 представляет собой полнофункциональный инструмент, обеспечивающий автоматизированный процесс количественного сравнения алгоритмов. Он служит как инструментом для апробации новых методов, предложенных в диссертации, так и обучающей платформой для студентов, изучающих современные подходы к обработке изображений.

4.4 Пользовательский интерфейс комплекса IMPROC 3.0

Пользовательский интерфейс программного комплекса IMPROC 3.0 разработан на базе современного фреймворка PySide6, являющегося официальной привязкой к библиотеке Qt5 для языка Python. Благодаря использованию этой технологии обеспечивается кроссплатформенная совместимость, интуитивность, модульность и наглядность интерфейса (рис. 4.1).

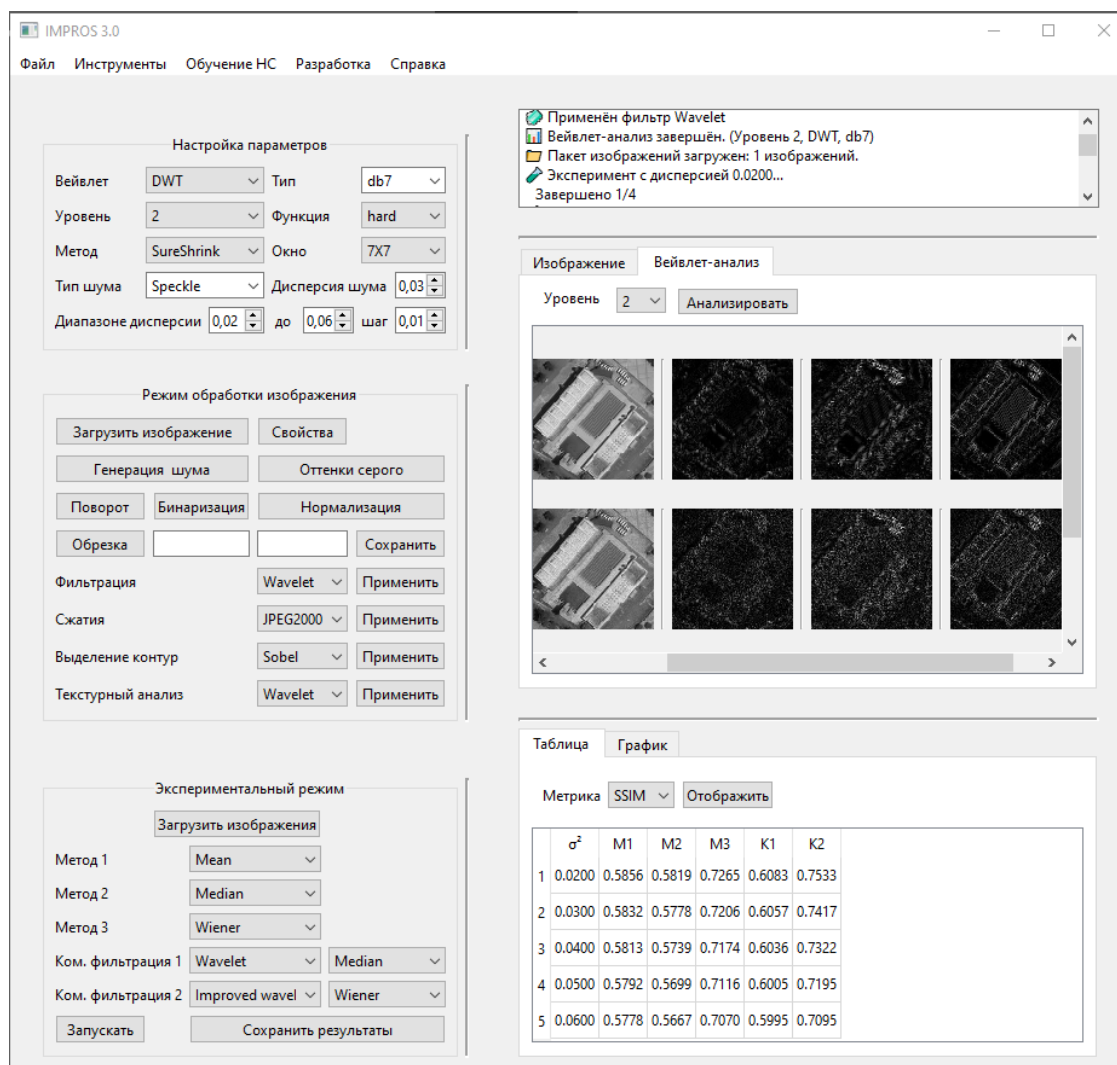


Рисунок 4.1 – Пользовательский интерфейс программного комплекса IMPROC 3.0

Интерфейс организован в шесть отдельных областей, каждая из которых выполняет определенные функции при взаимодействии пользователя с комплексом.

Область 1: Панель настроек алгоритмов.

Расположена в верхней левой части главного окна и включает выпадающие списки и числовые поля для выбора или ручного ввода значений, необходимых для используемых методов, в частности, параметров, связанных с вейвлет-преобразованиями (рис. 4.2).

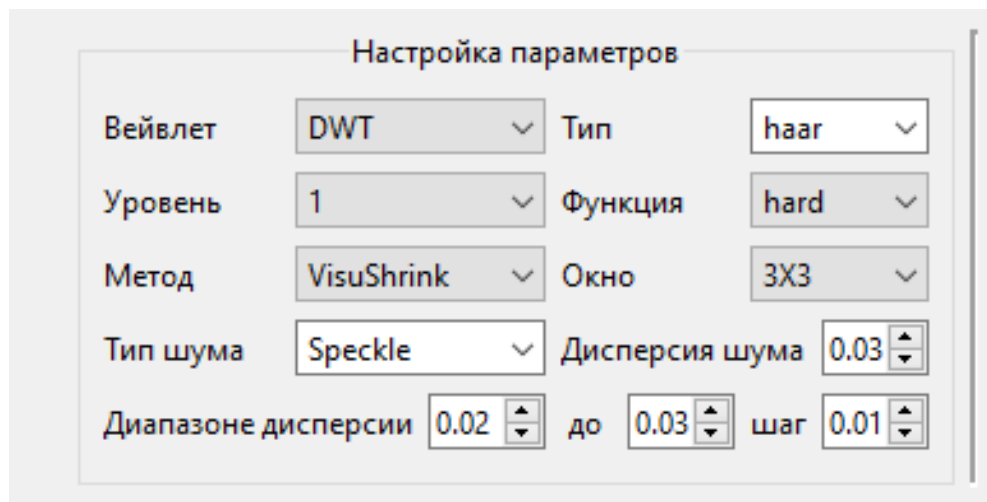


Рисунок 4.2 – Панель настройки параметров

В этой области пользователь может:

- выбрать метод определения значения порога при использовании пороговой обработки вейвлет-коэффициентов (VisuShrink, SureShrink, BayesShrink), тип пороговой функции (soft/hard);
- задать параметры вейвлет-преобразования: тип вейвлета (haar, db4, sym4, coif3, bior4.4, CDF 9/7 и др.), уровень декомпозиции, алгоритм вейвлет-преобразования (DWT, SWT);
- задать размеры скользящих окон пространственных фильтров, таких как усредняющий фильтр, медианный фильтр, фильтр Ли и т. д.;
- выбрать тип шума и его уровень (или диапазона уровня шума с указанием начального, конечного значения и шага при работе в режиме экспериментов);

Область 2: Управление режимом обработки изображения

Расположена в центральной левой части и содержит компактную панель инструментов для работы с отдельным изображением (рис. 4.3):

- кнопка «загрузить изображение» открывает стандартный диалог выбора файла, в котором можно выбрать изображение для последующей обработки;
- кнопка «свойства» отображает основные характеристики загруженного изображения (размер, формат, глубина цвета и т.д.);
- кнопка «генерация шума» добавляет к изображению заданный тип шума (например, гауссовский или спекл-шум);
- кнопка «оттенки серого» преобразует цветное изображение в оттенки серого;
- кнопка «поворот» поворачивает изображение на 90 градусов;
- кнопка «бинаризация» преобразует изображение в чёрно-белое с использованием порогового значения;
- кнопка «нормализация» приводит диапазон яркости пикселей к стандартному интервалу $[0,1]$;
- кнопка «обрезка» обрезает изображение до указанного размера;
- выпадающий список «методы фильтрации». выбирает методы фильтрации шума (например, медианный фильтр, вейвлет-фильтрация, NLM и др.);
- выпадающий список «методы сжатия» предлагает выбор методов для сжатия изображения;
- выпадающий список «методы выделения контуров» выбирает алгоритм обнаружения границ объектов (например, Canny, Sobel, Laplacian и др.);
- выпадающий список «методы текстурного анализа» выбирает методы для оценки локальной структуры изображения;
- кнопки «Применить» запускают обработку изображения выбранными методами;

- кнопка «Сохранить» сохраняет обработанное изображение в указанный пользователем файл.

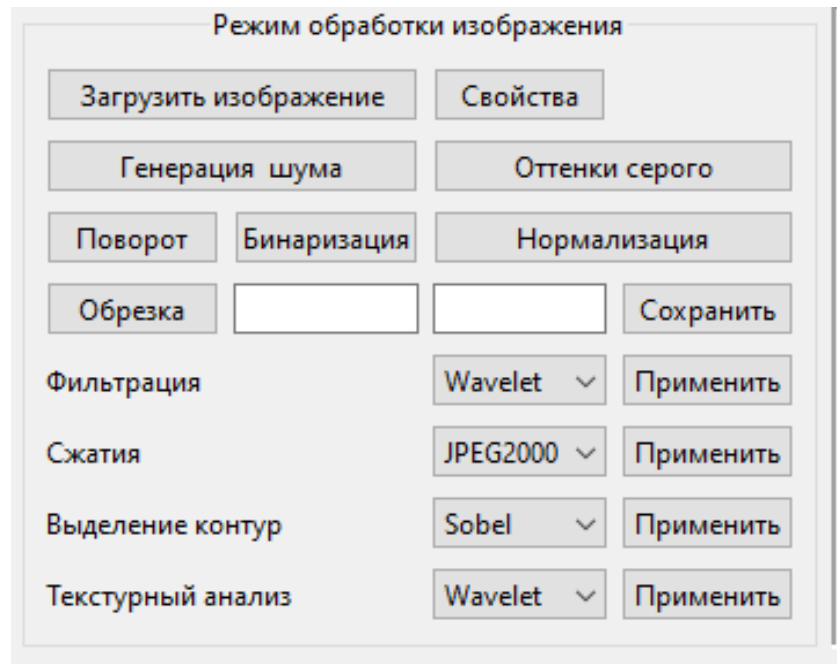


Рисунок 4.3 – Панель управления режимом обработки изображения

Область 3: Управление экспериментальным режимом

Расположена в нижней левой части и содержит элементы управления для работы в режиме экспериментов (рис. 4.4):

- кнопка «загрузить изображения» открывает стандартный диалог выбора файла, в котором можно выбрать набор изображений;
- выпадающие списки «методы 1», «методы 2», «методы 3» выбирают отдельные методы фильтрации, участвующие в сравнительном анализе.
- кнопка «Запустить» запускает эксперимент;
- кнопка «сохранить» сохраняет результаты эксперимента в табличной и графической формах вместе с параметрами его проведения.

Интерфейс экспериментального режима спроектирован так, чтобы минимизировать количество кликов и обеспечить полный контроль над условиями эксперимента, что соответствует требованиям научной строгости.

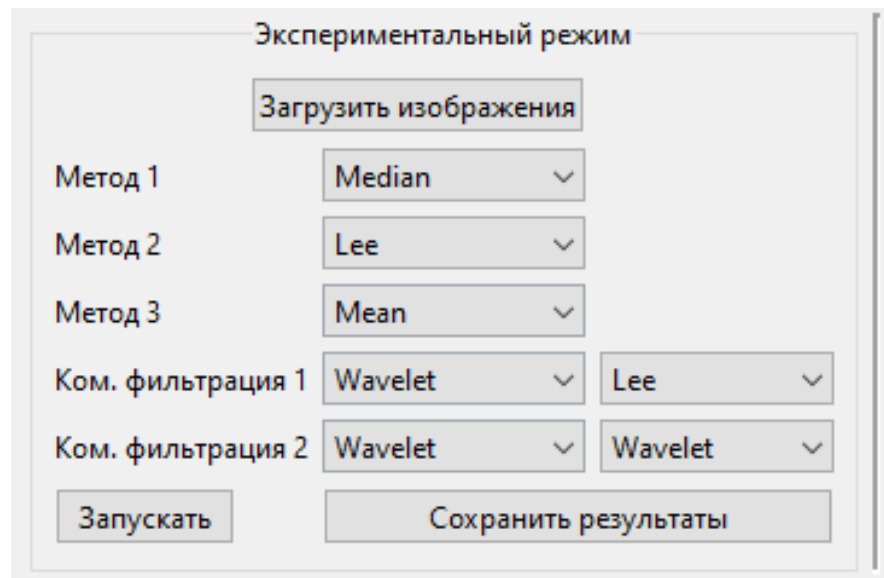


Рисунок 4.4 – Панель управления экспериментальным режимом

Область 4: Лог-панель

Размещена в верхней правой части главного окна и служит для отображения служебных сообщений в реальном времени:

- статус текущей операции («программа запущена», «применение фильтра ...», «эксперимент завершён» и т. д.);
- уведомления об ошибках (некорректный формат файла, отсутствие модели нейросети и т.п.);
- время выполнения операций;

Область 5: Визуальная область результатов обработки изображения

Занимает центральную правую часть главного окна и реализована в виде многостраничного виджета (QTabWidget). Основные вкладки:

- «изображение» отображает загруженное, зашумленное и обработанное изображение, а также их гистограммы (рис. 4.5);
- «вейвлет-анализ» визуализирует вейвлет-коэффициенты аппроксимации и деталей на заданном уровне декомпозиции, что даёт возможность наблюдать и анализировать изменения вейвлет-коэффициентов до и после обработки (рис. 4.6);

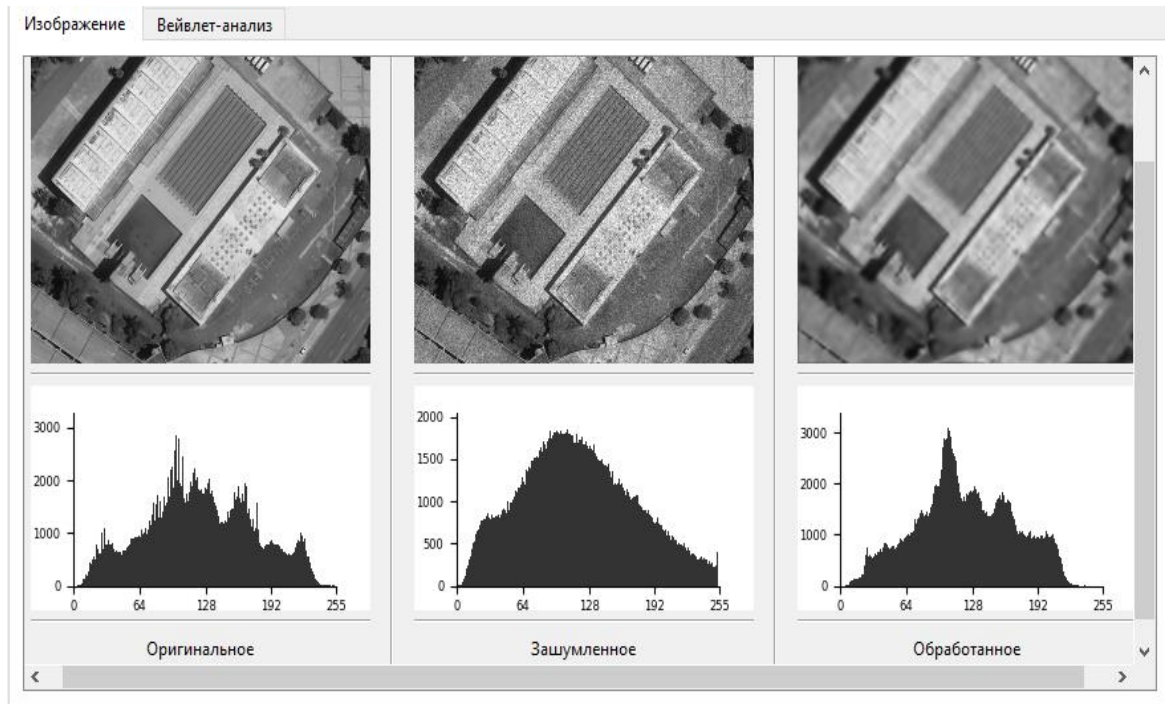


Рисунок 4.5 – Визуальная область отображения результатов обработки изображения

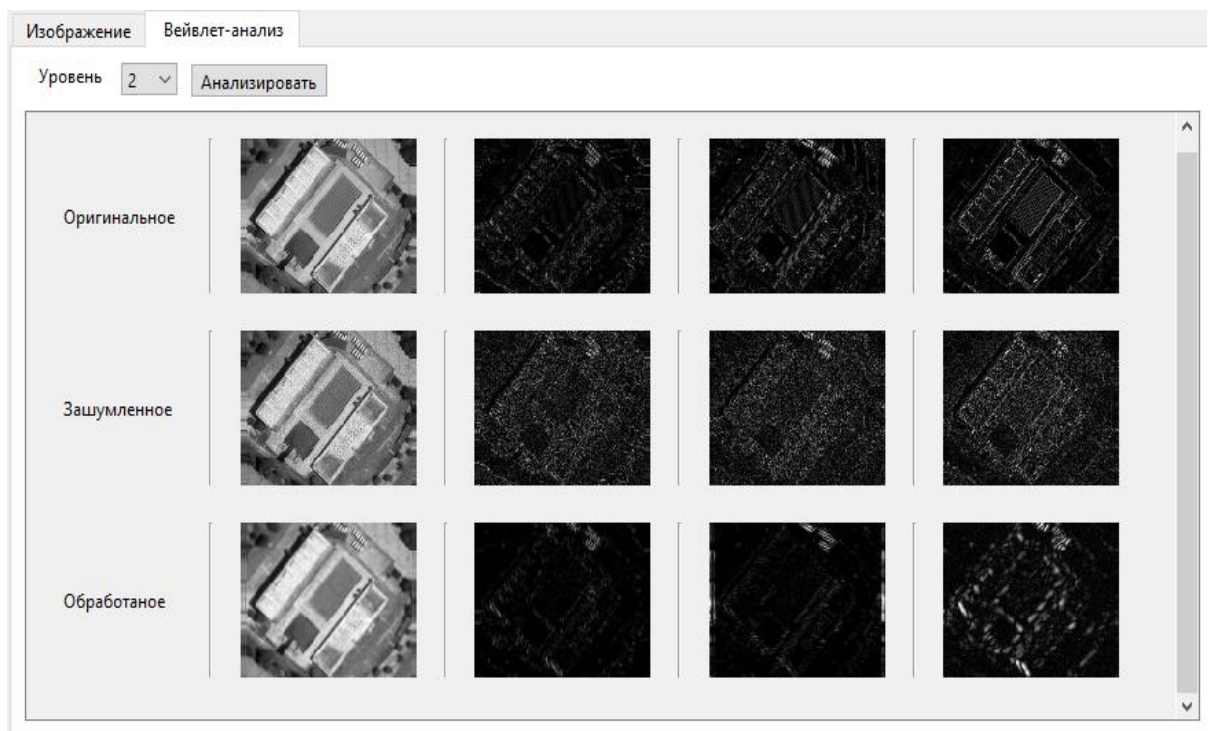


Рисунок 4.6 – Визуальная область отображения вейвлет-коэффициентов

Все визуальные компоненты используют интерактивные средства масштабирования, цветовые палитры, и инструменты измерения, что делает анализ глубоким и наглядным.

Область 6: Отображение экспериментальных результатов

Размещена в нижней правой части главного окна и служит для отображения результатов сравнительного анализа. Эта область также реализована в виде многостраничного виджета, состоящего из 2 основных вкладок:

- «таблица» позволяет выбирать метрику оценки качества и отображать её значения в табличной форме, где строки соответствуют уровням шума, а столбцы — используемым методам (рис. 4.7);
- «график» позволяет выбирать метрику оценки качества и отображать её значения в графической форме, построенной с помощью Matplotlib [144] и интегрированной через FigureCanvasQtAgg (рис. 4.8).

Эта область обеспечивает количественную интерпретацию результатов и служит основой для формирования выводов в научных работах и отчётах.

Таким образом, пользовательский интерфейс IMPROC 3.0 представляет собой целостную, логически структурированную среду, что обеспечивает воспроизводимость вычислительных экспериментов и удобство анализа результатов. Он объединяет преимущества современных библиотек Python с продуманной эргономикой, что делает комплекс эффективным инструментом как в учебном процессе, так и в научных исследованиях по обработке изображений.

	σ^2	M1	M2	M3	K1	K2
1	0.0100	0.5563	0.5787	0.6382	0.5832	0.6788
2	0.0200	0.5486	0.5606	0.6173	0.5761	0.6530
3	0.0300	0.5435	0.5481	0.5969	0.5713	0.6331
4	0.0400	0.5360	0.5350	0.5744	0.5635	0.6097
5	0.0500	0.5305	0.5251	0.5566	0.5585	0.5930
6	0.0600	0.5265	0.5166	0.5400	0.5528	0.5728

Рисунок 4.7 – Вкладок отображения результатов сравнительного анализа в виде в табличной форме

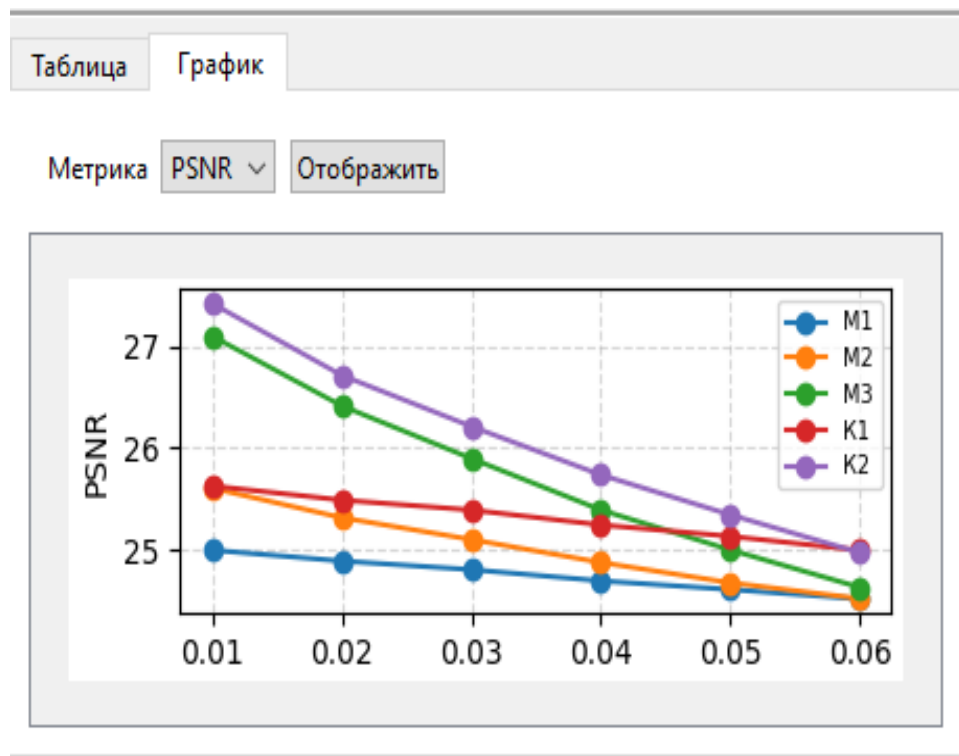


Рисунок 4.8 – Вкладок отображения результатов сравнительного анализа в виде в графической форме

4.5 Применение программного комплекса IMPROC 3.0 в учебном и исследовательском процессе

Программный комплекс IMPROC 3.0 разработан как универсальный инструмент, объединяющий в себе учебные, исследовательские функции. Его архитектура и пользовательский интерфейс ориентированы как на студентов, осваивающих основы цифровой обработки изображений, так и на магистрантов, аспирантов и научных сотрудников, проводящих передовые исследования в области обработки изображений.

4.5.1 Применение IMPROC 3.0 в учебном процессе

IMPROC 3.0 используется при проведении лабораторных работ по следующим дисциплинам:

- «Методы сжатия изображений» — студенты изучают основные подходы к сжатию изображений, включая методы сжатия без потерь (EZW, SPIHT), методы сжатия с потерями (JPEG, JPEG 2000, WebP), а также модифицированный алгоритм SPIHT, разработанный для обработки и сжатия зашумленных

изображений. В рамках курса рассматриваются принципы работы указанных алгоритмов, проводится сравнительный анализ их эффективности, а также исследуется влияние степени сжатия на качество восстановленных изображений;

- «Методы машинного обучения» — в рамках курса демонстрируется применение глубоких нейронных сетей (U-Net, DnCNN) для решения задач шумоподавления; студенты осваивают методы генерации синтетических обучающих данных, оценки качества моделей с использованием количественных метрик, а также проводят сравнительный анализ методов машинного обучения и традиционных алгоритмов обработки изображений;

- «Предварительная обработка изображений» — студенты изучают классические методы фильтрации изображений (медианный фильтр, фильтр Винера, фильтры Ли и Фроста), осваивают принципы вейвлет-преобразования, исследуют влияние параметров обработки на качество изображений и выполняют сравнительный анализ эффективности различных методов фильтрации.

Интуитивно понятный интерфейс, возможность визуального сопоставления изображений «до» и «после» обработки, оперативный расчёт количественных метрик качества, а также поддержка пошагового применения методов обработки делают комплекс особенно удобным для использования в учебном процессе, где важны наглядность, воспроизводимость результатов и возможность проведения вычислительных экспериментов без необходимости программирования.

4.5.2 Применение IMPROC 3.0 в исследовательском процессе

IMPROC 3.0 представляет собой многофункциональную исследовательскую платформу, ориентированную на интеграцию теоретических основ обработки изображений с практическими средствами их алгоритмической реализации, анализа и экспериментальной верификации. Разработанный комплекс обеспечивает возможность не только применения известных методов обработки изображений, но и проведения полномасштабных вычислительных исследований, направленных на проверку научных гипотез, оценку эффективности предлагаемых подходов и подготовку результатов к публикации в научных изданиях. Существенным преимуществом платформы является поддержка строгой

количественной оценки качества обработки изображений, что позволяет проводить объективное сопоставление разрабатываемых методов на основе системы формализованных критериев и метрик.

Функциональные возможности IMPROC 3.0 предусматривают гибкую настройку параметров существующих алгоритмов, расширение библиотеки методов за счёт включения новых моделей и вычислительных процедур, а также выполнение сравнительного анализа различных подходов в рамках единой программно-вычислительной среды. Такой подход создаёт благоприятные условия для воспроизводимого экспериментального исследования, при котором все этапы обработки, настройки параметров и оценки результатов реализуются в рамках унифицированной инфраструктуры.

Особое значение имеет адаптация платформы к современным условиям организации образовательной и научной деятельности. Комплекс может функционировать непосредственно в облачной вычислительной среде, в частности в Google Colab, что исключает необходимость локальной установки специализированного программного обеспечения и снижает требования к техническому оснащению пользователя. Возможность экспорта функциональности в формат Jupyter Notebook обеспечивает создание интерактивных учебных и исследовательских материалов, объединяющих теоретические пояснения, программную реализацию алгоритмов и средства визуального представления результатов. Использование облачных сервисов, таких как Google Drive, GitHub и других платформ коллективной работы, способствует обеспечению воспроизводимости экспериментов, упрощает обмен данными, конфигурациями и вычислительными сценариями, а также поддерживает совместную исследовательскую деятельность независимо от аппаратной и географической локализации участников.

В условиях активного развития дистанционных образовательных технологий и расширения международного научного взаимодействия указанные возможности приобретают особую актуальность. Платформа может эффективно использоваться как в учебном процессе при подготовке специалистов в области

цифровой обработки изображений, так и в научно-исследовательской работе, связанной с разработкой, тестированием и сравнительной оценкой новых методов анализа и обработки визуальных данных.

Таким образом, IMPROC 3.0 следует рассматривать не только как программный инструмент прикладного назначения, но и как интегрированную научно-образовательную среду, обеспечивающую условия для подготовки высококвалифицированных специалистов, проведения современных вычислительных исследований и разработки перспективных методов обработки изображений.

4.6 Выводы по четвертой главе

В четвертой главе рассмотрены программная реализация разработанных алгоритмов обработки зашумленных изображений, а также их практическое применение в составе программного комплекса IMPROC 3.0.

1. Разработана новая версия программного комплекса IMPROC 3.0, объединяющая в единой программной среде классические методы фильтрации, методы на основе вейвлет-преобразования, комбинированные подходы, а также алгоритмы с использованием нейронных сетей. Показано, что программный комплекс обеспечивает возможность сопоставления различных методов обработки изображений в одинаковых условиях, выявления их преимуществ и ограничений, а также выбора наиболее эффективных подходов к фильтрации изображений, искажённых шумом.

2. Показано, что модульная архитектура программного комплекса IMPROC 3.0 обеспечивает интеграцию различных алгоритмов обработки изображений, возможность расширения их набора, а также проведение вычислительных экспериментов в рамках единой программной платформы. Это создаёт необходимые условия для апробации разработанных методов и их сравнительного анализа по заданным критериям качества.

3. В составе программного комплекса реализованы два основных режима функционирования: режим обработки отдельного зашумлённого изображения и экспериментальный режим, предназначенный для проведения серии

вычислительных экспериментов и сравнительной оценки эффективности различных методов обработки изображений. Установлено, что такая организация программного комплекса обеспечивает как практическое применение разработанных алгоритмов, так и их исследование в контролируемых условиях.

ЗАКЛЮЧЕНИЕ

В диссертации решена научно-техническая задача разработки алгоритмов вейвлет-фильтрации и нейросетевой обработки изображений, искаженных мультипликативным шумом, имеющая важное теоретическое и прикладное значение. В рамках решения поставленной задачи получены следующие основные результаты.

1. Модифицированный алгоритм пороговой обработки вейвлет-коэффициентов с усилением НЧК в высокочастотных субполосах, который позволяет повысить ПОСШ в среднем на 4,6 дБ, SSIM – на 48 %, а также снизить GMSD в среднем на 40 % по сравнению с исходным зашумлённым изображением.

2. Адаптивный алгоритм пороговой обработки вейвлет-коэффициентов с локальной оценкой дисперсии шума, который позволяет повысить ПОСШ в среднем на 5,4 дБ, SSIM – на 56 %, а также снизить GMSD в среднем на 45 % по сравнению с исходным зашумлённым изображением.

3. Алгоритм фильтрации зашумленных изображений на основе пороговой вейвлет-обработки и фильтра Винера с использованием текстурного анализа, который позволяет повысить ПОСШ в среднем на 4,9 дБ, SSIM – на 52 %, а также снизить GMSD в среднем на 43 % по сравнению с исходным зашумлённым изображением.

4. Алгоритм фильтрации зашумленных изображений на основе применения метода NLM в области вейвлет-преобразования, который позволяет повысить ПОСШ в среднем на 5,2 дБ, SSIM – на 58 %, а также снизить GMSD в среднем на 47 % по сравнению с исходным зашумлённым изображением.

5. Алгоритм фильтрации зашумленных изображений на основе применения архитектуры нейронной сети U-Net в области вейвлет-преобразования, который позволяет повысить ПОСШ в среднем на 6,9 дБ, SSIM – на 69 %, а также снизить GMSD в среднем на 62 % по сравнению с исходным зашумлённым изображением.

6. Алгоритм обработки ПОД вейвлет-коэффициентов с использованием архитектуры рекуррентной нейронной сети LSTM, который позволяет повысить

ПОСШ в среднем на 5,8 дБ, SSIM – на 58 %, а также снизить GMSD в среднем на 54 % по сравнению с исходным зашумлённым изображением.

7. Алгоритм обработки ПОД вейвлет-коэффициентов с использованием архитектуры нейронной сети трансформера, который позволяет повысить ПОСШ в среднем на 6,0 дБ, SSIM – на 62 %, а также снизить GMSD в среднем на 52 % по сравнению с исходным зашумлённым изображением.

8. Программный комплекс IMPROC, интегрирующий разработанные алгоритмы.

СПИСОК СОКРАЩЕНИЙ

БВП	– Быстрое вейвлет-преобразование
ДВП	– Дискретное вейвлет-преобразование
ДЗЗ	– Дистанционное зондирование Земли
КВП-ДД	– Комплексное вейвлет-преобразование «двойного дерева»
НЧК	– Низкочастотная компонента
ПОД	– Пространственно-ориентированное дерево
ПОСШ	– Пиковое отношение сигнал-шум
РЛИ	– Радиолокационное изображение
РСА	– Радар с синтезированной апертурой
СВП	– Стационарное вейвлет-преобразование
СКО	– Среднеквадратичная ошибка
ЦОС	– Цифровая обработка сигналов
CNN	– Свёрточная нейронная сеть
GMSD	– Отклонение подобия величины градиента
MS-SSIM	– Многомасштабный индекс структурного сходства
LSTM	– Сеть долгой краткосрочной памяти
NLM	– Метод нелокального усреднения
RNN	– Рекуррентная нейронная сеть
SSIM	– Индекс структурного сходства
SURE	– Несмещённая оценка риска Штейна
U-Net	– U-образная архитектура свёрточной нейронной сети

СПИСОК ЛИТЕРАТУРЫ

1. Gonzalez, R.C. Digital Image Processing / R.C. Gonzalez, R.E. Woods. – 4th ed. – Pearson, 2018. – 1019 p.
2. Jain, A.K. Fundamentals of Digital Image Processing / A.K. Jain. – Englewood Cliffs: Prentice Hall, 1989. – 569 p.
3. Pratt, W.K. Digital Image Processing / W.K. Pratt. – 4th ed. – Hoboken: Wiley, 2007. – 782 p.
4. Bovik, A.C. Handbook of Image and Video Processing. – 2nd ed. – Academic Press, 2005. – 1372 p.
5. Goodman, J.W. Some fundamental properties of speckle / J.W. Goodman // Journal of the Optical Society of America. – 1976. – Vol. 66. – № 11. – P. 1145–1150.
6. Goodman, J.W. Speckle Phenomena in Optics: Theory and Applications / J.W. Goodman. – 2nd ed. – Bellingham: SPIE Press, 2020.
7. Dainty, J.C. Laser Speckle and Related Phenomena / J.C. Dainty. – Berlin: Springer, 1975.
8. Burckhardt, C.B. Speckle in ultrasound B-mode scans / C.B. Burckhardt // IEEE Transactions on Sonics and Ultrasonics. – 1978. – Vol. 25. – № 1. – P. 1–6.
9. Wagner, R.F. Statistics of speckle in ultrasound B-scans / R.F. Wagner, S.W. Smith, J.M. Sandrik, H. Lopez // IEEE Transactions on Sonics and Ultrasonics. – 1983. – Vol. 30. – № 3. – P. 156–163.
10. Schmitt, J.M. Speckle in optical coherence tomography / J.M. Schmitt, S.H. Xiang, K.M. Yung // Journal of Biomedical Optics. – 1999. – Vol. 4. – № 1. – P. 95–105.
11. Aubert, G. A variational approach to removing multiplicative noise / G. Aubert, J.F. Aujol // SIAM Journal on Applied Mathematics. – 2008. – Vol. 68. – № 4. – P. 925–946.
12. Huang, Y.-M. A new total variation method for multiplicative noise removal / Y.-M. Huang, M.K. Ng, Y.-W. Wen // SIAM Journal on Imaging Sciences. – 2009. – Vol. 2. – № 1. – P. 20–40.

13. Zaki, F. Noise adaptive wavelet thresholding for speckle noise removal in optical coherence tomography / F. Zaki et al. // *Biomedical Optics Express*. – 2017.
14. Gour, N. Speckle denoising in optical coherence tomography images using residual deep convolutional neural network / N. Gour, P. Khanna // *Multimedia Tools and Applications*. – 2020.
15. Lee, J.S. Speckle filtering of synthetic aperture radar images: A review / J.S. Lee, I. Jurkevich, P. Dewaele, P. Wambacq, A. Oosterlinck // *Remote Sensing Reviews*. – 1994. – Vol. 8. – № 4. – P. 313–340.
16. Chan, D. Speckle noise reduction in SAR images using information theory / D. Chan, J. Gambini, A. C. Frery // *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. – 2020. – Vol. XLII-3/W12-2020. – P. 141–146.
17. Oliver, C. *Understanding Synthetic Aperture Radar Images* / C. Oliver, S. Quegan. – Raleigh: SciTech Publishing, 2004. – 479 p.
18. Гусев, С.И. Цифровая обработка данных радиолокационного зондирования Земли из космоса: учебное пособие / С.И. Гусев, Н.А. Егошкин, В.В. Еремеев и др. – М.: КУРС, 2021. – 248 с.
19. Kuan, D.T. Adaptive noise smoothing filter for images with signal-dependent noise / D.T. Kuan, A.A. Sawchuk, T.C. Strand, P. Chavel // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 1985. – Vol. PAMI-7. – № 2. – P. 165–177.
20. Lee, J.S. Digital image enhancement and noise filtering by use of local statistics / J.S. Lee // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 1980. – Vol. PAMI-2. – № 2. – P. 165–168.
21. Lopes, A. Adaptive speckle filters and scene heterogeneity / A. Lopes, R. Touzi, E. Nezry // *IEEE Transactions on Geoscience and Remote Sensing*. – 1990. – Vol. 28. – № 6. – P. 992–1000.
22. Lopes, A. Maximum a posteriori speckle filtering and first order texture models in SAR images / A. Lopes, R. Touzi, E. Nezry // *IGARSS*. – 1990. – P. 2409–2412.

23. Touzi, R. A review of speckle filtering in the context of estimation theory / R. Touzi // *IEEE Transactions on Geoscience and Remote Sensing*. – 2002. – Vol. 40. – № 11. – P. 2392–2404.
24. Frost, V.S. An adaptive filter for smoothing noisy radar images / V.S. Frost, J.A. Stiles, K.S. Shanmugan, J.C. Holtzman // *Proceedings of the IEEE*. – 1982. – Vol. 70. – № 1. – P. 57–62.
25. Yu, Y. Speckle reducing anisotropic diffusion / Y. Yu, S.T. Acton // *IEEE Transactions on Image Processing*. – 2002. – Vol. 11. – № 11. – P. 1260–1270.
26. Burrus, C.S. *Introduction to Wavelets and Wavelet Transforms: A Primer* / C.S. Burrus, R.A. Gopinath, H. Guo. – Upper Saddle River: Prentice Hall, 1998. – 268 p.
27. Vetterli, M. *Wavelets and Subband Coding* / M. Vetterli, J. Kovacevic. – NJ: Prentice Hall PTR, 1995. – 522 p.
28. Vidakovic, B. *Statistical Modeling by Wavelets* / B. Vidakovic. – New York: Wiley, 1999. – 416 p.
29. Daubechies, I. *Ten Lectures on Wavelets* / I. Daubechies. – Philadelphia: SIAM, 1992. – 357 p.
30. Donoho, D.L. Ideal spatial adaptation by wavelet shrinkage / D.L. Donoho, I.M. Johnstone // *Biometrika*. – 1994. – Vol. 81. – № 3. – P. 425–455.
31. Donoho, D.L. De-noising by soft-thresholding / D.L. Donoho // *IEEE Transactions on Information Theory*. – 1995. – Vol. 41. – № 3. – P. 613–627.
32. Donoho, D.L. Adapting to unknown smoothness via wavelet shrinkage / D.L. Donoho, I.M. Johnstone // *Journal of the American Statistical Association*. – 1995. – Vol. 90. – № 432. – P. 1200–1224.
33. Mallat, S. A theory for multiresolution signal decomposition: the wavelet representation / S. Mallat // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 1989. – Vol. 11. – № 7. – P. 674–693.
34. Mallat, S. *A Wavelet Tour of Signal Processing* / S. Mallat. – 3rd ed. – Amsterdam: Academic Press, 2009. – 805 p.
35. Strang, G. *Wavelets and Filter Banks* / G. Strang, T. Nguyen. – Wellesley: Wellesley-Cambridge Press, 1996. – 492 p.

36. Unser, M. Ten good reasons for using spline wavelets / M. Unser // Proc. SPIE. – 1997. – Vol. 3169. – P. 422–431.
37. Wickerhauser, M.V. Adapted Wavelet Analysis from Theory to Software / M.V. Wickerhauser. – Wellesley: A.K. Peters, 1994. – 486 p.
38. Selesnick, I.W. The dual-tree complex wavelet transform / I.W. Selesnick, R.G. Baraniuk, N.G. Kingsbury // IEEE Signal Processing Magazine. – 2005. – Vol. 22. – № 6. – P. 123–151.
39. Алексеев, К.А. Вейвлет-ряды в задаче оценивания собственных частот датчиков // Датчики и системы. – 2001. – № 12. – С. 2– 5.
40. Алпатов, Б.А. Методы и алгоритмы обработки изображений в системах управления // Учеб. пособие. Рязань: РГРТУ, 1999. – 64 с.
41. Витязев, В.В. Цифровая частотная селекция сигналов. – М.: Радио и связь, 1993. – 240 с.
42. Воробьев, В.И. Теория и практика вейвлет-преобразования / В.И. Воробьев, В.Г. Грибунин. – Санкт-Петербург: ВУС, 1999. – 206 с.
43. Цифровая обработка телевизионных и компьютерных изображений / Дворкович А.В., Дворкович В.П., Зубарев Ю.Б. и др. – М.: МЦНТИ, 1997.
44. Демьянович Ю.К., Ходаковский В.А. Введение в теорию вейвлетов: учебное пособие. СПб.: Изд-во ПГУПС, 2008. – 50 с.
45. Кравченко, В.Ф., Рвачев, В.Л. «Wavelet»-системы и их применение в обработке сигналов // Зарубежная радиоэлектроника. – 1996. – № 4. – С. 3–20.
46. Новиков, И.Я. Теория всплесков / И.Я. Новиков, В.Ю. Протасов, М.А. Скопина. – М.: Физматлит, 2005.
47. Петухов, А.П. Введение в теорию базисов всплесков. - СПб.: Изд-во СПбГТУ, 1999. – 132 с.
48. Приоров, А. Л. Цифровая обработка изображений: учеб. пособие / И. В. Апальков, В. В. Хрящев; Яросл. гос. ун-т; А. Л. Приоров. – Ярославль: ЯрГУ, 2007. – 235 с
49. Методы компьютерной обработки изображений / под ред. В.А. Сойфера. – 2-е изд., испр. – М.: Физматлит, 2003.

50. Фурсов, В.А. Технология повышения детализации изображений с нелинейной коррекцией высокоградиентных фрагментов / В.А. Фурсов, Е.В. Гошин, К.С. Медведева // Компьютерная оптика. – 2019. – Т. 43, № 3. – С. 484–491.
51. Дондик, Е.М. Вейвлет-преобразования в информационных системах: учебное пособие / Е.М. Дондик. – Рязань: РГРТУ, 2015. – 48 с.
52. Астафьева, Н.М. Вейвлет-анализ: основы теории и примеры применения / Н.М. Астафьева // Успехи физических наук. – 1996. – Т. 166. – № 11. – С. 1145–1170.
53. Дьяконов, В.П. Вейвлеты. От теории к практике / В.П. Дьяконов. – М.: СОЛОН-Пресс, 2021. – 397 с.
54. Смоленцев, Н.К. Основы теории вейвлетов. Вейвлеты в MATLAB / Н.К. Смоленцев. – М.: ДМК Пресс, 2019. – 560 с.
55. Захарова, Т.В. Вейвлет-анализ и его приложения: учебное пособие / Т.В. Захарова, О.В. Шестаков. – 2-е изд., перераб. и доп. – М.: ИНФРА-М, 2025. – 158 с.
56. Bruce, A. WaveShrink: shrinkage functions and thresholds / A. Bruce, H.-Y. Gao // Proc. SPIE. – 1995. – Vol. 2569. – P. 175–186.
57. Chang, S.G. Adaptive wavelet thresholding for image denoising and compression / S.G. Chang, B. Yu, M. Vetterli // IEEE Transactions on Image Processing. – 2000. – Vol. 9. – № 9. – P. 1532–1546.
58. Sendur, L. Bivariate shrinkage functions for wavelet-based denoising exploiting interscale dependency / L. Sendur, I.W. Selesnick // IEEE Transactions on Signal Processing. – 2002. – Vol. 50. – № 11. – P. 2744–2756.
59. Portilla, J. Image denoising using scale mixtures of Gaussians in the wavelet domain / J. Portilla, V. Strela, M.J. Wainwright, E.P. Simoncelli // IEEE Transactions on Image Processing. – 2003. – Vol. 12. – № 11. – P. 1338–1351.
60. Pizurica, A. A versatile wavelet domain noise filtration technique for medical imaging / A. Pizurica, W. Philips // IEEE Transactions on Medical Imaging. – 2003. – Vol. 22. – № 3. – P. 323–331.
61. Coifman, R.R. Translation-invariant de-noising / R.R. Coifman, D.L. Donoho // Lecture Notes in Statistics. – 1995. – Vol. 103. – P. 125–150.

62. Nason, G.P. Stationary and nonstationary wavelet packets / G.P. Nason, B.W. Silverman // *Journal of the Royal Statistical Society. Series B.* – 1995. – Vol. 57. – № 2. – P. 479–499.
63. Crouse, M.S. Wavelet-based statistical signal processing using hidden Markov models / M.S. Crouse, R.D. Nowak, R.G. Baraniuk // *IEEE Transactions on Signal Processing.* – 1998. – Vol. 46. – № 4. – P. 886–902.
64. Mihçak, M.K. Low-complexity image denoising based on statistical modeling of wavelet coefficients / M.K. Mihçak, I. Kozintsev, K. Ramchandran, P. Moulin // *IEEE Signal Processing Letters.* – 1999. – Vol. 6. – № 12. – P. 300–303.
65. Luisier, F. A new SURE approach to image denoising: interscale orthonormal wavelet thresholding / F. Luisier, T. Blu, M. Unser // *IEEE Transactions on Image Processing.* – 2007. – Vol. 16. – № 3. – P. 593–606.
66. Aiazzi, B. New trends in despeckling: undecimated wavelet shrinkage and fuzzy matching / B. Aiazzi, L. Alparone, S. Baronti, A. Garzelli // *Proc. SPIE.* – 2002. – Vol. 4543. – P. 317–328.
67. Achim, A. SAR image denoising via Bayesian wavelet shrinkage / A. Achim, P. Tsakalides, A. Bezerianos // *IEEE Transactions on Image Processing.* – 2003. – Vol. 12. – № 12. – P. 1600–1613.
68. Argenti, F. Speckle removal from SAR images in the undecimated wavelet domain / F. Argenti, L. Alparone // *IEEE Transactions on Geoscience and Remote Sensing.* – 2002. – Vol. 40. – № 11. – P. 2363–2374.
69. Argenti, F. Multiresolution MAP despeckling of SAR images based on locally adaptive generalized Gaussian pdf modeling / F. Argenti, T. Bianchi, L. Alparone // *IEEE Transactions on Image Processing.* – 2006. – Vol. 15. – № 11. – P. 3385–3399.
70. Bianchi, T. Segmentation-based MAP despeckling of SAR images in the undecimated wavelet domain / T. Bianchi, F. Argenti, L. Alparone // *IEEE Transactions on Geoscience and Remote Sensing.* – 2008. – Vol. 46. – № 9. – P. 2728–2742.
71. Bianchi, T. Amplitude versus intensity Bayesian despeckling in the wavelet domain / T. Bianchi, F. Argenti, L. Alparone // *Digital Signal Processing.* – 2013. – Vol. 23. – № 4. – P. 1253–1265.

72. Mastriani, M. SAR image despeckling based on fuzzy thresholding in the wavelet domain / M. Mastriani // *International Journal of Remote Sensing*. – 2011. – Vol. 32. – № 10. – P. 2669–2686.
73. Xie, H. Speckle reducing and edge preserving anisotropic diffusion for SAR image despeckling in the wavelet domain / H. Xie, L.E. Pierce, F.T. Ulaby // *IEEE International Geoscience and Remote Sensing Symposium*. – 2002. – P. 1540–1542.
74. Foucher, S. Wavelet-based SAR image filtering and Markov random field modeling / S. Foucher, G.B. Benie // *IEEE Transactions on Geoscience and Remote Sensing*. – 2002. – Vol. 40. – № 11. – P. 2360–2372.
75. Parrilli, S. A nonlocal SAR image denoising algorithm based on LLMMSE wavelet shrinkage / S. Parrilli, M. Poderico, C.V. Angelino, L. Verdoliva // *IEEE Transactions on Geoscience and Remote Sensing*. – 2012. – Vol. 50. – № 2. – P. 606–616.
76. Тузова, А.А. Подавление мультипликативного шума на радиолокационных изображениях / А.А. Тузова, Н.С. Ширококов // *Компьютерная оптика*. – 2021. – Т. 45. – № 6. – С. 945–954.
77. Burger, W. *Digital Image Processing: An Algorithmic Introduction Using Java* / W. Burger, M.J. Burge. – 2nd ed. – London: Springer, 2016. – 811 p.
78. Sonka, M. *Image Processing, Analysis, and Machine Vision* / M. Sonka, V. Hlavac, R. Boyle. – 4th ed. – Cengage Learning, 2014. – 829 p.
79. Castleman, K.R. *Digital Image Processing* / K.R. Castleman. – Upper Saddle River: Prentice Hall, 1996. – 667 p.
80. Rudin, L.I. Nonlinear total variation-based noise removal algorithms / L.I. Rudin, S. Osher, E. Fatemi // *Physica D*. – 1992. – Vol. 60. – P. 259–268.
81. Buades, A. A review of image denoising algorithms, with a new one / A. Buades, B. Coll, J.M. Morel // *Multiscale Modeling & Simulation*. – 2005. – Vol. 4. – № 2. – P. 490–530.
82. Milanfar, P. A Tour of Modern Image Filtering: New Insights and Methods, Both Practical and Theoretical / P. Milanfar // *IEEE Signal Processing Magazine*. – 2013. – Vol. 30. – № 1. – P. 106–128.

83. Wang, Z. Image quality assessment: from error visibility to structural similarity / Z. Wang, A.C. Bovik, H.R. Sheikh, E.P. Simoncelli // *IEEE Transactions on Image Processing*. – 2004. – Vol. 13. – № 4. – P. 600–612.
84. Wang, Z. Multiscale structural similarity for image quality assessment / Z. Wang, E.P. Simoncelli, A.C. Bovik // *37th Asilomar Conference on Signals, Systems and Computers*. – 2003. – Vol. 2. – P. 1398–1402.
85. Hore, A. Image quality metrics: PSNR vs. SSIM / A. Hore, D. Ziou // *ICPR*. – 2010. – P. 2366–2369.
86. Zhang, L. FSIM: a feature similarity index for image quality assessment / L. Zhang, L. Zhang, X. Mou, D. Zhang // *IEEE Transactions on Image Processing*. – 2011. – Vol. 20. – № 8. – P. 2378–2386.
87. Xue, W. Gradient magnitude similarity deviation: a highly efficient perceptual image quality index / W. Xue, L. Zhang, X. Mou, A.C. Bovik // *IEEE Transactions on Image Processing*. – 2014. – Vol. 23. – № 2. – P. 684–695.
88. LeCun, Y. Deep learning / Y. LeCun, Y. Bengio, G. Hinton // *Nature*. – 2015. – Vol. 521. – P. 436–444.
89. Goodfellow, I. *Deep Learning* / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge, MA: MIT Press, 2016. – 775 p.
90. Zhang, Q. Deep Learning for SAR Image Despeckling: A Review / Q. Zhang, Y. Yuan, J. Li // *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. – 2021. – Vol. 14. – P. 5300–5315.
91. He, K. Deep residual learning for image recognition / K. He, X. Zhang, S. Ren, J. Sun // *CVPR*. – 2016. – P. 770–778.
92. Ronneberger, O. U-Net: convolutional networks for biomedical image segmentation / O. Ronneberger, P. Fischer, T. Brox // *MICCAI*. – 2015. – Pt. III. – P. 234–241.
93. Hochreiter, S. Long short-term memory / S. Hochreiter, J. Schmidhuber // *Neural Computation*. – 1997. – Vol. 9. – № 8. – P. 1735–1780.
94. Graves, A. *Supervised sequence labelling with recurrent neural networks* / A. Graves. – Berlin: Springer, 2012. – 385 p.

95. Cho, K. Learning phrase representations using RNN encoder-decoder for statistical machine translation / K. Cho et al. // EMNLP. – 2014. – P. 1724–1734.
96. Pascanu, R. On the difficulty of training recurrent neural networks / R. Pascanu, T. Mikolov, Y. Bengio // ICML. – 2013. – P. 1310–1318.
97. Greff, K. LSTM: a search space odyssey / K. Greff et al. // IEEE Transactions on Neural Networks and Learning Systems. – 2017. – Vol. 28. – № 10. – P. 2222–2232.
98. Vaswani, A. Attention is all you need / A. Vaswani, N. Shazeer, N. Parmar, et al. // Advances in Neural Information Processing Systems. – 2017. – Vol. 30. – P. 5998–6008.
99. Dosovitskiy, A. An image is worth 16x16 words: transformers for image recognition at scale / A. Dosovitskiy et al. // ICLR. – 2021.
100. Devlin, J. BERT: pre-training of deep bidirectional transformers for language understanding / J. Devlin, M.-W. Chang, K. Lee, K. Toutanova // NAACL-HLT. – 2019. – P. 4171–4186.
101. Bahdanau, D. Neural machine translation by jointly learning to align and translate / D. Bahdanau, K. Cho, Y. Bengio // ICLR. – 2015.
102. Carion, N. End-to-end object detection with transformers / N. Carion et al. // ECCV. – 2020. – P. 213–229.
103. Touvron, H. Training data-efficient image transformers and distillation through attention / H. Touvron et al. // ICML. – 2021. – P. 10347–10357.
104. Wang, P. SAR-GAN: generative adversarial networks for SAR image despeckling / P. Wang, H. Zhang, V.M. Patel // IEEE ICIP. – 2020. – P. 305–309.
105. Dalsasso, E. SAR2SAR: a self-supervised despeckling algorithm for SAR images / E. Dalsasso, L. Denis, F. Tupin // IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. – 2021. – Vol. 14. – P. 9972–9985.
106. Chierchia, G. SAR image despeckling through convolutional neural networks / G. Chierchia, D. Cozzolino, G. Poggi, L. Verdoliva // IEEE Geoscience and Remote Sensing Letters. – 2017. – Vol. 14. – № 4. – P. 488–492.

107. Taher, A. Residual U-Net for SAR image despeckling – a lightweight and effective deep learning approach / A. Taher, L. Al-Wadai, R. Al-Malki // IEEE Space, Aerospace and Defence Conference. – 2025. – P. 1–3.

108. Zhang, K. Beyond a Gaussian denoiser: residual learning of deep CNN for image denoising / K. Zhang, W. Zuo, Y. Chen, D. Meng, L. Zhang // IEEE Transactions on Image Processing. – 2017. – Vol. 26. – № 7. – P. 3142–3155.

109. Павлов, В.А. Сравнение архитектур нейронных сетей для подавления мультипликативного шума на изображениях / В.А. Павлов, А.А. Белов, В.Т. Нгуен, Н. Йовановски, А.С. Овсянникова // Компьютерная оптика. – 2024. – Т. 48. – № 3. – С. 425–431.

110. Павлов, В.А. Применение обученных на оптических изображениях сверточных нейронных сетей для обнаружения объектов на радиолокационных изображениях / В.А. Павлов, А.А. Белов, С.В. Волвенко, А.В. Рашич // Компьютерная оптика. – 2024. – Т. 48. – № 2. – С. 253–259.

111. Митькин, М.А. Применение искусственных нейронных сетей для восстановления объектов на радиолокационных изображениях / М.А. Митькин, К.Ю. Гаврилов // Труды МАИ. – 2025. – № 3. – С. 1–21.

112. Степанов, Г.Ю. Интеграция искусственного интеллекта в обработку данных радиолокационной станции с синтезированной апертурой / Г.Ю. Степанов // Известия ТулГУ. Технические науки. – 2026. – № 1. – С. 112–121.

113. Бехтин, Ю.С. Теоретические основы цифровой обработки изображений встроенных оптико-электронных систем / Ю.С. Бехтин, С.Г. Емельянов, Д.В. Титов. – М.: Аргамак-Медиа, 2016. – 296 с.

114. Бехтин, Ю.С. Теоретические основы вейвлет-кодирования зашумленных сигналов: монография / Ю.С. Бехтин.– Рязань: РГРТУ, 2009. – 124 с.

115. Бехтин, Ю.С. Методы и алгоритмы вейвлет-кодирования зашумленных изображений в радиотехнических системах // Диссертация на соискание ученой степени доктора технических наук по спец. 05.12.04, 2009.

116. Баранцев, А.А. Алгоритмы вейвлет-анализа и компенсации геометрических шумов сигналов тепловизионных систем с матричными

фотоприемниками // Диссертация на соискание ученой степени кандидата технических наук по спец. 05.13.01 2012.

117. Бехтин, Ю.С. Обработка зашумленных изображений на основе вейвлет-преобразований // Вестник РГРТУ. – 2006. – № 18. – С. 141–144.

118. Бехтин, Ю.С. Алгоритм вейвлет-фильтрации зашумленных изображений // Вестник РГРТА. – 2004. – № 15. – С. 22–27.

119. Бехтин, Ю.С. Улучшение качества зашумленных изображений на основе вейвлет-преобразований // Проблемы математического моделирования и обработки информации в научных исследованиях: сб. науч. тр. – Рязань: РГРТА, 2003. – 9 с.

120. Бехтин, Ю.С., Брянцев, А.А. Подавление спекл-шума на основе анализа множеств зашумленных и неискаженных данных изображений в системах машинного зрения // Тез. докл. VII МНТК «Распознавание». – Курск, 2005. – 2 с.

121. Брянцев, А.А. Комбинированная фильтрация изображений, полученных с помощью радаров с синтезированной апертурой // Вестник РГРТУ. – 2007. – № 21. – С. 16–20.

122. Бехтин, Ю.С., Брянцев, А.А., Астапенко, М.П. Комбинированная фильтрация изображений, полученных с помощью радаров с синтезированной апертурой // Обработка информации в автоматических системах: сб. науч. тр. – Рязань: РГРТУ, 2006. – 6 с.

123. Копенков, В.Н. Алгоритм автоматического построения границ объектов на изображении на основе локального дискретного вейвлет-преобразования / В.Н. Копенков, Н.В. Коновалов // Компьютерная оптика. – 2012. – Т. 36. – № 4. – С. 605–611.

124. Бехтин, Ю.С. Интеграция зашумленных мультиспектральных изображений на основе пространственно-ориентированных деревьев вейвлет-преобразования / Ю.С. Бехтин // Цифровая обработка сигналов. – 2012. – № 1. – С. 27–31.

125. Peng, F. Extended SOT Wavelet Packet Coding Algorithm for Remote Sensing Images / F. Peng, P. Yingjun, W. Biao, M. Deling, J. Shuqing, J. Wei // 2007

IEEE International Symposium on Industrial Electronics. – Vigo, Spain, 2007. – P. 1590–1594.

126. Bekhtin, Yu.S. Non-destructive wavelet-based despeckling in SAR images / Yu.S. Bekhtin, A.A. Bryantsev, D.P. Malebo, A.A. Lupachev // SAR Image Analysis, Modeling, and Techniques XIV. – 2014. – Vol. 9243. – 92430B.

127. Bekhtin, Yu.S. Onboard joint nondestructive despeckling and wavelet-based data compression of multilook synthetic aperture radar images using reordered spatial oriented trees / Yu.S. Bekhtin // Journal of Applied Remote Sensing. – 2015. – Vol. 9. – № 1. – P. 097494.

128. Bekhtin, Yu.S. Wavelet-based fusion of noisy multispectral images using Spatial Oriented Trees / Yu.S. Bekhtin, A.A. Bryantsev, D.P. Malebo // 2013 2nd Mediterranean Conference on Embedded Computing (MECO). – Budva, Montenegro, 2013. – P. 113–116.

129. Чинь, В.Т. Сравнение эффективности различных типов вейвлетов при шумоподавлении изображений, полученных с помощью радаров с синтезированной апертурой / Ю.С. Бехтин, В.Т. Чинь // Материалы IX Всеросс. НТК «Актуальные проблемы современной науки и производства». – Рязань, 2024. – С. 342–349.

130. Чинь, В.Т. Вейвлет-фильтрация зашумленных изображений с использованием их аппроксимаций в субполосах деталей / Ю.С. Бехтин, В.Т. Чинь // ГрафиКон 2024. – Омск, 2024. – С. 525–531.

131. Bekhtin, Yu.S. Wavelet-based Filtering of Noisy Images by Amplification of Low-Frequency Components in High-Frequency Subbands / Yu.S. Bekhtin, V.T. Trinh // DSPA 2025. – Moscow, 2025. – P. 1–4.

132. Чинь, В.Т. Вейвлет-фильтрация зашумленных изображений на основе выделения контуров объектов и низкочастотных компонентов в субполосах деталей / Ю.С. Бехтин, В.Т. Чинь // Материалы XVIII Междунар. НТК «Опτικο-электронные приборы и устройства в системах распознавания образов и обработки изображений». – Курск, 2025. – С. 59–61.

133. Чинь, В.Т. Адаптивный метод фильтрации спекл-шума изображений, полученных с помощью радаров с синтезированной апертурой на основе вейвлет-преобразования / Ю.С. Бехтин, В.Т. Чинь // *Материалы X Всеросс. НТК «Актуальные проблемы современной науки и производства»*. – Рязань, 2025. – С. 480–487.

134. Чинь, В.Т. Комбинирование пространственной и частотной фильтрации для подавления спекл-шума изображений / В.Т. Чинь // *Форум «Современные технологии в науке и образовании»*. – Рязань, 2025. – С. 131–136.

135. Trinh, V.T. Combined Speckle Removal Based on the Wiener Filter and Wavelet Transform using Texture Analysis / Y.S. Bekhtin, V.T. Trinh // *REEPE 2025*. – Moscow, 2025. – P. 1–5.

136. Чинь, В.Т. Метод фильтрации спекл-шума изображений, полученных с помощью радаров с синтезированной апертурой на основе вейвлет-преобразования и нелокального усреднения / В.Т. Чинь // *Инженерный вестник Дона*. – 2026. – № 2.

137. Чинь, В.Т. Подавление спекл-шума изображений на основе усиления низкочастотных компонент в высокочастотных субполосах вейвлет-преобразования с использованием нейронной сети U-Net / Ю.С. Бехтин, В.Т. Чинь, А.В. Титова // *Инженерный вестник Дона*. – 2026. – № 2.

138. Чинь, В.Т. Фильтрация зашумленных изображений на основе нейросетевой обработки пространственно ориентированных деревьев вейвлет-преобразования / Ю.С. Бехтин, В.Т. Чинь // *Вестник РГРТУ*. – 2025. – № 94. – С. 114–123.

139. Чинь, В.Т. Фильтрация спекл-шума радиолокационных изображений на основе обработки пространственно-ориентированных деревьев вейвлет-преобразования с помощью трансформера / Ю.С. Бехтин, В.Т. Чинь // *Цифровая обработка сигналов*. – 2025. – № 4. – С. 75–81.

140. Lee, G.R. PyWavelets: a Python package for wavelet analysis / G.R. Lee, R. Gommers, F. Waselewski, K. Wohlfahrt, A. O’Leary // *Journal of Open-Source Software*. – 2019. – Vol. 4. – № 36. – 1237.

141. Paszke, A. PyTorch: an imperative style, high-performance deep learning library / A. Paszke et al. // *Advances in Neural Information Processing Systems*. – 2019. – Vol. 32. – P. 8024–8035.
142. Harris, C.R. Array programming with NumPy / C.R. Harris et al. // *Nature*. – 2020. – Vol. 585. – P. 357–362.
143. Virtanen, P. SciPy 1.0: fundamental algorithms for scientific computing in Python / P. Virtanen et al. // *Nature Methods*. – 2020. – Vol. 17. – № 3. – P. 261–272.
144. Hunter, J.D. Matplotlib: a 2D graphics environment / J.D. Hunter // *Computing in Science & Engineering*. – 2007. – Vol. 9. – № 3. – P. 90–95.
145. Bradski, G. *Learning OpenCV: Computer Vision with the OpenCV Library* / G. Bradski, A. Kaehler. – Sebastopol: O'Reilly, 2008. – 555 p.
146. Van Rossum, G. *Python 3 Reference Manual* / G. van Rossum, F.L. Drake Jr. – Scotts Valley: CreateSpace, 2009. – 242 p.
147. Pedregosa, F. Scikit-learn: machine learning in Python / F. Pedregosa et al. // *Journal of Machine Learning Research*. – 2011. – Vol. 12. – P. 2825–2830.
148. Van der Walt, S. scikit-image: image processing in Python / S. Van der Walt, J.L. Schönberger, J. Nunez-Iglesias, F. Boulogne, J.D. Warner, N. Yager, E. Gouillart, T. Yu, the scikit-image contributors // *PeerJ*. – 2014. – Vol. 2. – e453.
149. TAMPERE17 noise-free image database [Electronic resource]. – URL: <https://webpages.tuni.fi/imaging/tampere17/>.
150. The USC-SIPI Image Database [Electronic resource]. – URL: <https://sipi.usc.edu/database/database.php/>.

ПРИЛОЖЕНИЕ**III. Акты внедрения****CÔNG TY CỔ PHẦN THƯƠNG MẠI VÀ PHÁT TRIỂN CÔNG NGHỆ ĐIỆN TỬ E-STARS****GIẤY CHỨNG NHẬN**

Về việc ứng dụng kết quả luận án tiến sĩ của nghiên cứu sinh Trịnh Văn Toán trường “Đại học tổng hợp Kỹ thuật Vô tuyến Điện tử Ryazan mang tên V.F. Utkin” – Liên Bang Nga

Văn bản này xác nhận rằng các kết quả luận án Tiến sĩ của nghiên cứu sinh Trịnh Văn Toán trong việc xây dựng và phát triển các thuật toán khử nhiễu đốm (speckle) trong hình ảnh trên cơ sở biến đổi wavelet đã được đưa vào ứng dụng trong hoạt động của công ty.

Các kết quả luận án được ứng dụng trong các hoạt động nghiên cứu và phát triển của công ty bao gồm: Thuật toán khử nhiễu đốm (speckle) trên cơ sở biến đổi wavelet với việc tăng cường các thành phần tần số thấp; Thuật toán xử lý ngưỡng thích nghi các hệ số wavelet; Các thuật toán khử nhiễu đốm trên cơ sở xử lý cây định hướng không gian (SOT) của các hệ số wavelet bằng các kiến trúc mạng nơ-ron.

Các kết quả của luận án được ứng dụng trong quá trình nghiên cứu, phát triển và thiết kế các mô-đun phần mềm tiền xử lý hình ảnh. Ngoài ra phần mềm xử lý hình ảnh IMPROS 3.0 được xây dựng trong quá trình thực hiện luận án được ứng dụng trong việc kiểm nghiệm các phương pháp, thuật toán xử lý hình ảnh cho các hệ thống xử lý ảnh chuyên dụng của công ty.

Việc ứng dụng thực tiễn các kết quả của luận án đã góp phần cải thiện chất lượng khử nhiễu, nâng cao hiệu quả xử lý hình ảnh, đồng thời mở rộng cơ sở thuật toán của các công cụ, phần mềm do công ty phát triển.

Hà Nội, ngày 26 tháng 02 năm 2026

Giám đốc

Ninh Thành Nguyễn

Перевод с вьетнамского языка на русский язык

**АКЦИОНЕРНОЕ ОБЩЕСТВО ТОРГОВЛИ И РАЗВИТИЯ
ЭЛЕКТРОННЫХ ТЕХНОЛОГИЙ «E-STAR»**

АКТ

**о внедрении результатов диссертационной работы аспиранта
Чинь Ван Тоан
ФГБОУ ВО «Рязанский государственный радиотехнический университет
имени В. Ф. Уткина», Российская Федерация**

Настоящим актом подтверждается внедрение результатов диссертационной работы аспиранта Чинь Ван Тоан, посвященной разработке и совершенствованию алгоритмов подавления спекл-шума в изображениях на основе вейвлет-преобразования, в деятельность компании.

Результаты диссертационной работы внедрены в рамках научно-исследовательских и опытно-конструкторских работ компании, включая: алгоритм подавления спекл-шума на основе вейвлет-преобразования с усилением низкочастотных компонент; адаптивный алгоритм пороговой обработки вейвлет-коэффициентов; алгоритмы подавления спекл-шума на основе обработки пространственно-ориентированного дерева (SOT) вейвлет-коэффициентов с использованием архитектур нейронных сетей.

Полученные результаты применяются при исследовании, разработке и проектировании программных модулей предварительной обработки изображений. Кроме того, программное обеспечение IMPROS 3.0 для обработки изображений, разработанное в ходе выполнения диссертационной работы, используется для верификации методов и алгоритмов обработки изображений, предназначенных для специализированных систем компании.

Практическое внедрение результатов работы позволило повысить качество подавления шума, увеличить эффективность обработки изображений, а также расширить алгоритмическую базу устройств и программного обеспечения, разрабатываемых компанией.

Ханой, 26 февраля 2026 г

ДИРЕКТОР

(Подписано и скреплено печатью)

Печать: АКЦИОНЕРНОЕ ОБЩЕСТВО ТОРГОВЛИ И
РАЗВИТИЯ ЭЛЕКТРОННЫХ ТЕХНОЛОГИЙ «E-STAR»

Идентификатор: 0109855349-С.Т.С.Р * Город Ханой/

Нинь Тхань Нгуен

Перевод данного текста выполнен переводчиком Рахманиной Викторией Александровной

Российская Федерация

Город Москва

Тринадцатого апреля две тысячи двадцать шестого года

Я, Карнаухова Айгуль Энгельсовна, нотариус города Москвы, свидетельствую подлинность подписи переводчика Рахманиной Викторией Александровны.

Подпись сделана в моем присутствии.

Личность подписавшего документ установлена.

Зарегистрировано в реестре: № 77/236-н/77-2026-10-1695

Уплачено за совершение нотариального действия: 400 руб. 00 коп.



А.Э. Карнаухова



Пронумеровано, прошнуровано и скреплено печатью 2 листа (ов)

Нотариус

УТВЕРЖДАЮ

Проректор

по образовательной деятельности
ФГБОУ ВО «РГРТУ»

 _____ Е.А. Соколова

«30» _____ 2026 г.

АКТ

о внедрении результатов диссертационной работы Чинь Ван Тоан в учебный процесс ФГБОУ ВО «Рязанский государственный радиотехнический университет имени В. Ф. Уткина»


Настоящим актом подтверждается, что результаты научных исследований, полученные в кандидатской диссертации Чинь В. Т., внедрены в учебный процесс ФГБОУ ВО «Рязанский государственный радиотехнический университет им. В. Ф. Уткина».

Разработанные в диссертации алгоритмы вейвлет-фильтрации и нейросетевой обработки зашумленных изображений на основе усиления низкочастотных компонент используются при проведении лекционных, лабораторных и практических занятий по дисциплинам «Методы сжатия изображений» и «Предварительная обработка изображений».

При проведении лабораторных работ используется разработанный программный комплекс «IMPROC» версии 3.0, который наряду с известными алгоритмами обработки изображений включает алгоритмы вейвлет-фильтрации и нейросетевой обработки изображений, разработанные в диссертации.

Использование результатов, полученных в кандидатской диссертации Чинь В. Т., позволило повысить качество учебного процесса и ознакомить студентов с современными разработками в области обработки изображений.

 И. о. декана факультета АИТУ _____  А. А. Брянцев

 Председатель методической комиссии факультета АИТУ _____  А. В. Губарев

 Заведующий кафедрой АИТУ _____  П. В. Бабаян

П2. Свидетельства о государственной регистрации программы для ЭВМ

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025662318

**Программа комбинированной фильтрации спекл-шума
на основе фильтра Винера и вейвлет-преобразования с
помощью текстурного анализа**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
"Рязанский государственный радиотехнический
университет имени В.Ф. Уткина" (RU)*

Авторы: *Бехтин Юрий Станиславович (RU), Чинь Ван Тоан
(VN)*

Заявка № 2025661174

Дата поступления **06 мая 2025 г.**

Дата государственной регистрации

в Реестре программ для ЭВМ **20 мая 2025 г.**



*Руководитель Федеральной службы
по интеллектуальной собственности*

документ подписан электронной подписью
Сертификат: 0002e703d8-300c-4b42-90e7-0b6ca2026
Владелец: **Зубов Юрий Сергеевич**
Действителен с 2019.03.04 по 03.10.2025

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025691614

**Программа фильтрации спекл-шума на основе
обработки пространственно-ориентированных деревьев
вейвлет-преобразования LSTM рекуррентной
нейронной сетью**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Рязанский государственный радиотехнический
университет имени В.Ф. Уткина» (RU)*

Авторы: *Бехтин Юрий Станиславович (RU), Чинь Ван Тоан
(VN)*

Заявка № 2025691293

Дата поступления 17 ноября 2025 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 17 ноября 2025 г.



*Руководитель Федеральной службы
по интеллектуальной собственности*

документ подписан электронной подписью
Сертификат 00a570e4f7d430531b4b8818475f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 08.07.2025 по 28.11.2026

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2026611911

Программа фильтрации радиолокационных изображений на основе обработки пространственно-ориентированных деревьев вейвлет-преобразования с помощью трансформера

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего образования «Рязанский государственный радиотехнический университет имени В.Ф. Уткина» (RU)*

Авторы: *Бехтин Юрий Станиславович (RU), Чинь Ван Тоан (VN)*

Заявка № 2026610998

Дата поступления 22 января 2026 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 22 января 2026 г.



*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570e4f7c439531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 08.07.2025 по 28.11.2026

Ю.С. Зубов