

МИНИСТЕРСТВО ЦИФРОВОГО РАЗВИТИЯ,
СВЯЗИ И МАССОВЫХ КОММУНИКАЦИЙ РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Санкт-Петербургский государственный университет телекоммуникаций
им. проф. М.А. Бонч-Бруевича»

На правах рукописи

Грицкевич Иван Юрьевич

**ИССЛЕДОВАНИЕ И РАЗРАБОТКА МЕТОДОВ РЕАЛИЗАЦИИ
И ОБРАБОТКИ МАЛОКОНТРАСТНЫХ ИЗОБРАЖЕНИЙ
В УСЛОВИЯХ ОГРАНИЧЕННОЙ ВИДИМОСТИ**

2.2.13. Радиотехника,
в том числе системы и устройства телевидения

Диссертация на соискание ученой степени
кандидата технических наук

Научный руководитель:
д.т.н., профессор
Гоголь Александр Александрович

Санкт-Петербург – 2025

Содержание

ВВЕДЕНИЕ.....	5
ГЛАВА 1. Анализ методов повышения качества визуализации малоконтрастных изображений: постановка задачи исследования	11
1.1. Проблемы визуализации малоконтрастных объектов и изображений в условиях ограниченной видимости.....	11
1.1.1. Факторы, влияющие на качество изображений.....	11
1.1.2. Формализация понятия "малоконтрастное изображение": введение количественных критериев	13
1.1.3. Особенности обработки ИК-изображений.....	13
1.1.4. Особенности восприятия изображения человеком	18
1.2. Современные методы повышения контраста изображений	21
1.2.1. Глобальные методы	21
1.2.2. Локальные методы	25
1.2.3. Нейросетевые подходы	32
1.3. Критический анализ методов применительно к обработке малоконтрастных изображений	37
1.3.1. Недостаточная эффективность при сильном шуме.....	37
1.3.2. Потеря мелких деталей.....	37
1.3.3. Возникновение артефактов обработки	38
1.3.4. Высокая вычислительная сложность	39
1.3.5. Проблемы выбора параметров обработки.....	39
1.3.6. Нерешенные проблемы и вызовы	40
1.4. Методы оценки качества обработки изображений.....	42
1.4.1 Критерии визуальной оценки	42
1.4.2 Объективные метрики качества	43
1.4.3 Методы оценки эффективности алгоритмов компьютерного зрения	45
1.5. Постановка задачи исследования.	47
1.5.1. Цель исследования.....	47
1.5.2. Задачи исследования.....	47
1.5.3. Обоснование научной новизны	48
Выводы по главе 1	49

Глава 2. Теоретическое обоснование разработанного алгоритма.....	53
2.1. Динамическое скользящее окно	53
2.2. Адаптивный размер окна.....	54
2.3. Локальная энтропия	55
2.4. Частотный анализ.....	56
2.5. Безэталонная оценка качества	63
2.6. Ограничение контраста	66
2.7. Обеспечение использования нейросетевой модели	67
2.8. Обоснование адаптации алгоритма к ИК-изображениям.....	69
Выводы по главе 2.....	75
Глава 3. Практическая реализация на ПЛИС обработки изображения малоконтрастных объектов в условиях ограниченной видимости	77
3.1. Особенности реализации для контрастирования изображений.....	82
3.2 Исследование зависимости размера области обработки от коэффициентов ДКП при контрастировании изображений.	90
3.3. Особенности реализации алгоритмов контрастирования на ПЛИС.....	97
3.4. Модель архитектуры свёрточной нейронной сети	105
3.4.1. Обоснование архитектурных решений.....	108
3.4.2. Механизм адаптивного управления параметрами контраста.....	109
3.4.3. Функция потерь и методология обучения.....	109
3.4.4. Особенности реализации на ПЛИС	110
3.4.5. Экспериментальная валидация и метрики производительности	111
Вывод по главе 3.	113
Глава 4. Результаты экспериментальной проверки и практического внедрения разработанного комплексного метода обработки изображений	114
4.1. Основные особенности архитектуры ПЛИС и преимущества в обработке видеопотока и управления матрицей.	114
4.2. Реализация управления фоточувствительными матрицами.....	115
4.3. Алгоритм с разбиением гистограммы на области с оценкой по трём параметрам гистограммы	123
4.4. Сравнительный анализ вариантов управления экспозицией матрицы	124

4.5. Увеличение динамического диапазона методом сложения кадров с разной экспозицией	127
4.6. Увеличение динамического диапазона методом мульти экспозиции в одном кадре	128
4.7. Установление начальных параметров локального контрастирования при автоматической обработке цветных изображений	130
Заключение	138
Список сокращений и условных обозначений	142
Литература	144
Приложения	153

ВВЕДЕНИЕ

Одним из важных компонентов процесса интеллектуализации информационных технологий является все большая необходимость использования цифровых изображений. Такие технологии наиболее приемлемы и удобны для применения в системах видео наблюдения, автофокусировки в фото и видео камерах, медицинских приборах и т. д. Объем продаваемых программно-аппаратных средств, связанных с захватом, обработкой и хранением фото и видео изображений увеличивается ежегодно на 10 %. В случаях, когда съемка производится в условиях недостаточной освещенности, качество изображений значительно снижается из-за несовершенства фото и видео камер. Поэтому проблема повышения качества таких изображений является актуальной и представляет несомненный интерес.

Актуальность темы исследования.

В условиях ограниченной видимости (низкая освещенность, атмосферные помехи, окклюзии) качество изображений, особенно в инфракрасном (ИК) диапазоне, резко снижается из-за низкого отношения сигнал/шум (ОСШ), недостаточного динамического диапазона и наличия артефактов. Это существенно затрудняет анализ сцен из решения задач обнаружения, распознавания и сопровождения объектов.

Под «ограниченной видимостью» понимаются условия наблюдения, когда контраст между объектом и фоном слабый (объект наблюдения сложно отличим от фона), что усложняет их распознавание.

Традиционные методы повышения контрастности изображений, такие как гистограммная эквализация, гамма-коррекция и линейное контрастирование, ретинекс, не учитывают локальные особенности изображений, что приводит к усилению шума, потере мелких деталей и возникновению артефактов. Из вышеперечисленных методов наилучший результат даёт контрастно-ограниченная адаптивная эквализация гистограммы, но также имеет недостатки, связанные с артефактами (блочность, ореолы) и сложностью выбора параметров.

Современные нейросетевые подходы, демонстрирующие высокую эффективность в задачах улучшения изображений, требуют значительных вычислительных ресурсов и больших объемов исходных данных, что ограничивает их применение во встраиваемых системах реального времени.

Разработка адаптивных методов локального повышения контрастности, сочетающих в себе эффективность традиционных подходов и возможности современных нейросетевых технологий, при этом пригодных для реализации на встраиваемых платформах (ПЛИС), является актуальной научно-технической задачей. Решение этой задачи позволит существенно повысить точность обнаружения малоконтрастных объектов в условиях ограниченной видимости.

Степень разработанности темы.

Проблеме обработки малоконтрастных изображений в условиях ограниченной видимости посвятили работы такие отечественные авторы как: Ю. И. Белоусов, П. С. Баранов, А. А. Гоголь, , Н. А. Обухова, Ю. С. Сагдулаев, А. К. Цышулин, А. А. Храмичев, Г. И. Вишневский. Зарубежные авторы: D. Chandler, D. Doermann, A. Bovik, E. Simoncelli, H. Sheikh, J. Kumar, L. Zhang, P. Ye, Z. Wang.

Объект исследования.

Методы и алгоритмы повышения контрастности изображений в условиях ограниченной видимости.

Предмет исследования.

Обработка малоконтрастных цифровых изображений, направленная на повышение достоверности распознавания объектов.

Цель исследования.

Повышение контрастности и точности обнаружения объектов в режиме реального времени с учётом особенностей получателя информации (человека, нейронных сетей, элементов искусственного интеллекта).

Задачи работы:

1. Разработка методики оценки качества изображений для адаптации алгоритмов увеличения контраста.

2. Разработка новых быстродействующих методов конвейерного и параллельного вычисления адаптации изображений с использованием программируемых логических интегральных схем (ПЛИС).
3. Комплексные эксперименты и исследования вновь разработанных методов.
4. Внедрение результатов диссертационной работы в НИР и ОКР.

Научная новизна результатов исследования

Разработан новый гибридный метод локального контрастирования, в котором параметры обработки (размер окна, порог ограничения контраста) динамически определяются с использованием сверточной нейронной сети на основе анализа яркостных и текстурных особенностей, с учётом нестационарных фонов, обеспечивающий минимизацию артефактов.

Введены новые метрики качества изображений, основанные на анализе локальных контрастных изменений и учитывающие параметры человеческого восприятия и особенности применения элементов ИИ.

Разработана модель параллельной обработки изображений на ПЛИС, обеспечивающая сокращение времени обработки, при сохранении точности восстановления изображений.

Разработана легковесная архитектура сверточной нейронной сети (включающая сверточные и полносвязные слои с активацией ELU и пропускными соединениями) для регрессии оптимальных параметров алгоритма локального контрастирования изображений, обученная минимизировать безэталонную метрику качества и оптимизированная для аппаратной реализации на ПЛИС.

Теоретическая и практическая значимость.

Теоретическая значимость работы заключается в разработке гибридного подхода, где управление параметрами классического алгоритма контрастирования осуществляется нейронной сетью на основе анализа текстурных и частотных характеристик изображения, что обеспечивает адаптацию к сложным и нестационарным условиям наблюдения.

Практическая значимость работы определяется реализацией повышения контраста объектов изображений, полученных в видимом и ИК-диапазонах спектра и достоверностью их распознавания с использованием искусственного интеллекта.

Внедрение результатов диссертационной работы в НИР и ОКР подтверждено 5 актами внедрения:

- акт №1 АО «ЦКБ Фотон»
- акт №2 АО «КБП им. академика А. Г. ШИПУНОВА».
- акт №3 АО «НТЦ Элинс»
- акт №4 ПАО Красногорский завод им. С.А. Зверева
- акт №5 ЦКБ СпбГУТ

Методология и методы исследования.

Проведённые в работе исследования выполнены на положениях статистической теории связи (кумулятивные и интегральные функции распределения), теории вероятностей, дискретно косинусного преобразования, преобразования Фурье, преобразование Лейбница. Расчёт сложных моделей и результатов аппроксимаций и нахождение корней для преобразований включал в себя использование численных методов таких как метод Лагранжа. Прикладным программным пакетом был выбран Матлаб.

Положения, выносимые на защиту:

1. Алгоритм, основанный на модификации метода локальной эквализации гистограмм с динамическим определением размера локальной области обработки и адаптацией параметра ограничения контрастности к оцененному уровню шума, обеспечивает снижение артефактов в 2 раза для всего изображения и его деталей по сравнению с классическими методами гистограммной эквализации.
2. Гибридный метод, сочетающий адаптивное согласование динамических диапазонов и локальное контрастирование, параметры которого автоматически настраиваются с помощью легковесной сверточной нейронной сети на основе анализа изображения, увеличивает объективные

показатели качества для малоконтрастных изображений в условиях ограниченной видимости в 1,5 раза.

3. Реализация на ПЛИС разработанного гибридного алгоритма локального контрастирования, где легковесная сверточная нейронная сеть выполняет регрессию оптимальных параметров обработки для нейросетевых алгоритмов последующего анализа (например, детектирования), обеспечивает 6-кратное увеличение количества распознаваемых объектов при 20-кратном уменьшении времени обработки изображений.
4. Гибридный метод, объединяющий адаптивное локальное контрастирование с автоматической регулировкой его параметров при использовании сверточной нейронной сети, обеспечивает в задачах поиска людей 4-х кратное увеличение количества обнаружений и 15-кратное ускорение поиска по сравнению с результатами базового алгоритма локального контрастирования.

Степень достоверности и апробация результатов.

Достоверность полученных результатов подтверждена результатами аналитических расчётов и реализацией новых алгоритмов обработки реальных изображений. Результаты, полученные в ходе выполнения исследования, не противоречат ранее полученным данным, опубликованным в открытых источниках.

Апробация работы. Результаты работы докладывались и обсуждались на:

- международной научно-практической конференции по проблемам управления в технических системах (ПУТС - 2019 III International Conference on Control in Technical Systems (CTS) СПбГЭТУ «ЛЭТИ»);

- конференции «Актуальные проблемы инфо-телекоммуникаций в науке и образовании» (АПИНО 2021) Санкт-Петербургский государственный университет телекоммуникаций им. проф. М. А. Бонч-Бруевича;

- конференции «Актуальные проблемы радио - и кинотехнологий. Материалы V Международной научно-технической конференции, посвященной 140-летию со дня рождения выдающегося физика и создателя первой русской усилительной радиолампы Папалекси Н. Д.» СПб ГИКИТ (2021).

- конференции «Подготовка профессиональных кадров в магистратуре для цифровой экономики» (ПКМ-2020), Санкт-Петербургский государственный университет телекоммуникаций им. проф. Бонч-Бруевича М. А.

Публикации. По теме диссертации опубликованы 22 работы:

- в изданиях, рекомендованных ВАК при Минобрнауки России - 7;
- в других изданиях – 15;
- из них патентов – 6.

Соответствие паспорту научной специальности. Диссертационная работа соответствует пунктам 5, 7, 10 научной специальности 2.2.13 - Радиотехника, в том числе системы и устройства телевидения. Проведённые исследования соответствуют формуле специальности.

Личное участие соискателя. Все научные результаты получены соискателем лично.

ГЛАВА 1. Анализ методов повышения качества визуализации малоконтрастных изображений: постановка задачи исследования

1.1. Проблемы визуализации малоконтрастных объектов и изображений в условиях ограниченной видимости

Эффективность систем компьютерного зрения в различных приложениях напрямую зависит от качества входных изображений. Малоконтрастные изображения, характеризующиеся ограниченным диапазоном значений яркости и нечеткостью границ объектов, представляют собой серьезное препятствие для точного обнаружения, сопровождения и распознавания объектов и сцен.

1.1.1. Факторы, влияющие на качество изображений

На качество изображений в условиях низкой контрастности влияет совокупность факторов:

Факторы окружающей среды:

- **Низкая освещенность:** Недостаточный уровень освещенности приводит к снижению отношения сигнал/шум (ОСШ):
$$\text{ОСШ (дБ)} = 10 * \log_{10} (\text{Мощность сигнала} / \text{Мощность шума}) \quad (1.1)$$

отношение мощностей, а не амплитуд [1].
- **Атмосферные эффекты:** Атмосферное поглощение, рассеяние и турбулентность значительно ослабляют и искажают сигнал. Водяной пар, аэрозоли, туман, дым и перепады температур создают неоднородности и снижают общий контраст [2].
- **Окклюзии:** Частичное или полное перекрытие целевого объекта промежуточными объектами вносит резкие изменения интенсивности и скрывает детали.

Факторы, связанные с сенсором:

- **Ограниченный динамический диапазон:** Сенсоры имеют конечный диапазон интенсивностей. Если динамический диапазон сцены превышает

возможности сенсора, информация теряется в перенасыщенных или недоэкспонированных областях [1,2].



Рис. 1.1. Влияние высокой освещенности на качество изображения

- **Шум:** Основные источники шума включают:
 - Фотонный шум (распределение Пуассона)
 - Шум считывания
 - Темновой ток
 - Геометрический шум, (Fixed Pattern Noise, FPN), выражается в различных коэффициентах преобразования светового потока в различных пикселах [3].

Критически важным этапом предварительной обработки ИК - изображений является коррекция неоднородности (NUC), которая выполняется по формуле:

$$I_{\text{corrected}}(i, j) = a_{ij} * I_{\text{raw}}(i, j) + b_{ij} \quad (1.2)$$

где:

I_{raw} - исходное значение пикселя

$I_{\text{corrected}}$ - скорректированное значение

a_{ij}, b_{ij} - поправочные коэффициенты

1.1.2. Формализация понятия "малоконтрастное изображение": введение количественных критериев

Для объективной оценки "малоконтрастности" изображения и эффективности методов улучшения необходимы количественные метрики. Эти метрики должны коррелировать как с субъективным восприятием качества изображения человеком, так и с эффективностью последующих алгоритмов компьютерного зрения [4].

Локальные меры контрастности:

$$C_Michelson = (I_max - I_min) / (I_max + I_min) \quad (1.3)$$

где:

I_max и I_min - максимальная и минимальная интенсивности в локальном окне [1,5].

Энтропия изображения:

Энтропия Шеннона

$$H = - \sum p(i) * \log_2(p(i)) \quad (1.4)$$

где: $p(i)$ - вероятность появления пикселя с интенсивностью i [1,5]

1.1.3. Особенности обработки ИК-изображений

Инфракрасные (ИК) изображения, в отличие от изображений в видимом диапазоне, формируются за счет регистрации теплового излучения, испускаемого объектами. Это открывает широкие возможности для наблюдения в условиях низкой освещенности, тумана, дыма и т.д., но и создает ряд специфических проблем, которые необходимо учитывать при обработке ИК-изображений.

Обработка ИК-изображений имеет ряд особенностей по сравнению с изображениями в видимом диапазоне:

1. Температурная зависимость (рис. 1.2): Интенсивность излучения в ИК-диапазоне сильно зависит от температуры объекта (T) и его коэффициента излучения (ϵ) в соответствии с законом Стефана-Больцмана [3]:

Зависимость от температуры:

$$W = \epsilon \sigma T^4 \quad (1.5)$$

где:

- W - лучистая энергия
- ε - коэффициент излучения
- σ - постоянная Стефана-Больцмана
- T - абсолютная температура [4]




Рис. 1.2. Температурная зависимость ИК-излучения

Атмосферные эффекты:

Атмосфера оказывает *существенное* влияние на распространение ИК-излучения, особенно на больших расстояниях. Это влияние проявляется в виде:

- **Поглощения:** Молекулы газов (водяной пар, углекислый газ, озон и др.) поглощают ИК-излучение на определенных длинах волн, ослабляя сигнал, идущий от объекта.
- **Рассеяния:** Молекулы газов и аэрозольные частицы (пыль, дым, туман) рассеивают ИК-излучение, уменьшая контрастность и резкость изображения.
- **Излучения траектории:** Атмосфера сама излучает ИК-излучение, которое добавляется к сигналу от объекта, создавая дополнительный фон и снижая контрастность.

- **Турбулентность:** Неоднородности температуры и плотности в атмосфере вызывают случайные флуктуации показателя преломления, что приводит к мерцанию и размытию изображения.

Математическая модель атмосферных эффектов:

Излучение, принимаемое сенсором ($L_{received}$), можно представить в виде суммы излучения объекта, прошедшего через атмосферу, и излучения самой атмосферы (излучения траектории, L_{path}):

$$L_{received} = \tau_{atm} * L_{object} + L_{path} \quad (1.6)$$

где:

- $L_{received}$ — принимаемое излучение ($Вт/м^2 \cdot ср \cdot мкм$).
- τ_{atm} — пропускание атмосферы (безразмерная величина, от 0 до 1). Зависит от длины волны, состава атмосферы, расстояния до объекта и угла наблюдения.
- L_{object} — излучение объекта ($Вт/м^2 \cdot ср \cdot мкм$). Зависит от температуры и коэффициента излучения объекта.
- L_{path} — излучение траектории ($Вт/м^2 \cdot ср \cdot мкм$). Зависит от температуры и состава атмосферы на пути распространения излучения.

Пропускание атмосферы (τ_{atm}) является ключевым параметром, определяющим влияние атмосферы на ИК-изображение. Оно рассчитано с помощью специализированных программных пакетов, таких как MODTRAN [4], которые учитывают различные факторы (состав атмосферы, высоту, угол наблюдения, длину волны).

Для коррекции атмосферных эффектов необходимо оценить τ_{atm} и L_{path} и вычесть вклад атмосферы из принимаемого сигнала, чтобы получить оценку излучения объекта:

$$L_{object_estimated} = (L_{received} - L_{path}) / \tau_{atm} \quad (1.7)$$

Эта операция называется *атмосферной коррекцией*. Она является трудной задачей, требующей знания параметров атмосферы и использования сложных моделей.

Влияние атмосферных эффектов на контраст:

Атмосферные эффекты приводят к *уменьшению* контраста изображения. Это связано с тем, что:

- Поглощение и рассеяние ослабляют сигнал от объекта, уменьшая разницу между яркостями объекта и фона.
- Излучение траектории добавляет к сигналу фоновую составляющую, "засветляя" изображение и уменьшая контраст.

Специфика обработки ИК-изображений с учетом атмосферных эффектов:

- **Выбор спектрального диапазона:** Для минимизации влияния атмосферы необходимо выбирать спектральные диапазоны с *максимальным* пропусканием атмосферы ("окна прозрачности"). Например, для тепловизионных систем часто используются диапазоны 3-5 мкм (средневолновой ИК, MWIR) и 8-14 мкм (длинноволновой ИК, LWIR) [3].
- **Атмосферная коррекция:** Для получения точных данных о температуре объектов необходимо выполнять атмосферную коррекцию, учитывающую поглощение, рассеяние и излучение атмосферы.
- **Адаптивные методы обработки:** Алгоритмы повышения контрастности должны быть *адаптивными*, т.е. учитывать локальные изменения атмосферных условий и уровня шума.

В данной диссертации при разработке методов повышения контрастности малоконтрастных ИК-изображений учитываются все перечисленные выше особенности, что позволяет повысить эффективность обработки и обеспечить высокое качество получаемых результатов.

Калибровка и коррекция неоднородности:

Элементы матрицы ИК-детектора (особенно в неохлаждаемых микроболометрах) имеют разную чувствительность к ИК-излучению. Это приводит к появлению геометрического шума (*Fixed Pattern Noise, FPN*), который накладывается на полезный сигнал и проявляется в виде статического узора на изображении. Для устранения FPN необходима *коррекция неоднородности (Non-*

Uniformity Correction, NUC). NUC выполняется путем калибровки каждого пикселя с использованием источников излучения с известной температурой (черных тел). В результате калибровки для каждого пикселя (i, j) определяются коэффициенты усиления (a_{ij}) и смещения (b_{ij}), позволяющие скорректировать исходный сигнал:

$$I_{\text{corrected}}(i, j) = a_{ij} * I_{\text{raw}}(i, j) + b_{ij} \quad (1.8)$$

где

$I_{\text{raw}}(i, j)$ — исходное значение сигнала пикселя,

$I_{\text{corrected}}(i, j)$ — скорректированное значение.

Качество NUC напрямую влияет на качество ИК-изображения [3, 4, 6].

Из-за разной интенсивности излучения в зависимости от температуры и разной чувствительности датчиков и элементов светочувствительных матриц (рис.1.2, рис.1.3) большинство ТПВ приборов требуют калибровок неоднородности чувствительности по наблюдаемым тепловым полям.




Рис. 1.3. Зависимость интенсивности от температуры

1.1.4. Особенности восприятия изображения человеком

При разработке методов улучшения визуализации и, в частности, методов повышения контрастности, необходимо учитывать особенности человеческого зрительного восприятия. Человеческий глаз не является идеальным измерительным прибором, и его восприятие яркости и контраста подвержено ряду иллюзий и искажений. Среди наиболее важных факторов, влияющих на восприятие контраста, можно выделить:

1. **Полосы Маха:** Эффект усиления контраста на границах объектов с различной яркостью [1].

Это иллюзия усиления контраста на границах объектов с различной яркостью (рис.1.4). На границе между темной и светлой областями наблюдатель воспринимает несуществующие темную и светлую полосы, которых нет в реальном изображении. Этот эффект связан с латеральным торможением в сетчатке глаза [4]. При разработке алгоритмов повышения контрастности необходимо учитывать этот эффект, чтобы избежать появления ложных контуров.




Рис. 1.4. Иллюстрация эффекта полос Маха

2. Одновременный контраст:

Воспринимаемая яркость объекта зависит от яркости окружающего фона. Один и тот же объект будет казаться светлее на темном фоне и темнее на светлом фоне (рис.1.5). Этот эффект необходимо учитывать при локальном повышении контрастности, чтобы избежать искажения относительной яркости объектов в сцене.

Одновременный контраст: Восприятие яркости объекта зависит от яркости окружающего фона [1, 5, 9].



Рис. 1.5. Одновременный контраст

3. Адаптация к яркости:

Зрительная система человека адаптируется к среднему уровню яркости сцены. Это означает, что абсолютные значения яркости менее важны, чем относительные различия в яркости. Алгоритмы повышения контрастности должны учитывать этот эффект, чтобы обеспечить естественное восприятие изображения

$$L_{\text{perceived}} = k * \log(L_{\text{physical}} + 1) \quad (1.9)$$

где:

- $L_{\text{perceived}}$ - воспринимаемая яркость,
- L_{physical} - физическая яркость,
- k - константа адаптации [7-8].

Пространственная частота: Человеческий глаз имеет разную чувствительность к различным пространственным частотам. Наибольшая чувствительность наблюдается к средним частотам, соответствующим деталям среднего размера. Алгоритмы повышения контрастности должны учитывать эту особенность, чтобы не усиливать чрезмерно высокочастотный шум или низкочастотные изменения яркости, которые не несут полезной информации.

Цветовой контраст: Контраст может быть не только яркостным, но и цветовым. Человек хорошо различает цвета, даже если они имеют одинаковую яркость.

Маскирование: Наличие в изображении одних элементов (например, шума или текстуры) может маскировать (делать менее заметными) другие элементы (например, мелкие детали).

Учет этих особенностей зрительного восприятия позволяет разрабатывать более эффективные алгоритмы повышения контрастности, которые не только улучшают объективные показатели качества изображения, но и обеспечивают более естественное и комфортное восприятие изображения человеком.

1.2. Современные методы повышения контраста изображений

1.2.1. Глобальные методы

1. Гистограммная эквализация (HE):

Гистограммная эквализация стремится перераспределить интенсивности пикселей, чтобы получить более равномерную гистограмму (рис.1.6).

Кумулятивная функция распределения:

$$T(r_k) = (L-1) * \sum (n_i / N) \text{ (суммирование от } i=0 \text{ до } k) \quad (1.10)$$

где:

r_k - k -й уровень интенсивности,

n_i - количество пикселей с интенсивностью r_i ,

N - общее количество пикселей,

L - максимальный уровень интенсивности [1].




Рис. 1.6. Иллюстрация процесса гистограммной эквализации трехбитового изображения (8 уровней яркости).

(а) Исходная гистограмма, (б) Кумулятивная функция распределения.

(в) Функция преобразования, (г) Эквализованная гистограмма

Достоинства:

- Простота реализации
- Вычислительная эффективность $O(N)$

Недостатки:

- Усиление шума (20-30% при ОСШ < 25 дБ)
- Потеря деталей
- Неестественный вид
- Неприменимость к ИК-изображениям может скрывать тонкие детали в областях, которые изначально имели низкую, но значимую контрастность. Это особенно проблематично в ИК-изображениях, где небольшие перепады

температур могут иметь решающее значение для обнаружения и идентификации объектов.

- Не учитывает физические свойства ИК-излучения и особенности формирования ИК-изображений, он не подходит для данного применения.

2. Гамма-коррекция:

Гамма-коррекция — это нелинейное преобразование, которое регулирует общую яркость и контрастность изображения.

$$I_{out} = A * I_{in}^{\gamma} \quad (1.11)$$

где:

- I_{in} - входная интенсивность
- I_{out} - выходная интенсивность
- A - коэффициент масштабирования
- γ - показатель гамма [5]

На Рис. 1.7 гамма-коррекция и яркостная передаточная функция для различных значений γ .




Рис. 1.7. Графики функции гамма-коррекции и яркостная передаточная функция

На рис. 1.8 - форма амплитуды характеристик и их влияние на передачу градаций яркости изображений [1,5].




Рис.1.8. Гамма-коррекция

Достоинства:

- Простота реализации
- Улучшение воспринимаемой контрастности

Недостатки:

- Неравномерное освещение
- Ограниченная адаптивность
- Искажение гистограммы[15].

3. Линейное контрастирование:

$$I_{\text{out}} = (I_{\text{in}} - I_{\text{min}}) * (\text{MAX} - \text{MIN}) / (I_{\text{max}} - I_{\text{min}}) + \text{MIN} \quad (1.12)$$

где:

- I_{min} , I_{max} - минимальная и максимальная интенсивности входного изображения
- MIN, MAX - желаемые выходные интенсивности [1,5]

Недостатки:

Чувствительность к выбросам: Один очень яркий или очень темный пиксель (например, горячая точка в ИК-изображении) может значительно повлиять на $I_{\min}$ и $I_{\max}$, снижая эффективность растяжения.

Потеря информации: если исходное изображение имеет значения интенсивности, которые уже близки к желаемым MIN и MAX, растяжение может привести к насыщению и потере деталей (постеризации). Это серьезная проблема в ИК-изображениях, где тонкие колебания температуры могут иметь решающее значение.

Глобальная операция: Как и HE и гамма-коррекция, это глобальная операция, которая не адаптируется к локальным изменениям контрастности. Это делает его неэффективным для сцен с различным уровнем контрастности, которые распространены в ИК-изображениях из-за атмосферных эффектов и различной излучательной способности объектов.

1.2.2. Локальные методы

1. Адаптивная гистограммная эквализация (АНЕ):

$$T_{\text{tile}}(r_k) = (L-1) * \sum (n_i / N_{\text{tile}}) \quad (1.13)$$

где:

N_{tile} - количество пикселей в области обработки

n_i - количество пикселей с интенсивностью r_i внутри области обработки [1,5].

Данный метод эквализации отличается лишь тем, что вокруг каждого пикселя, вычисляется гистограмма. Для уменьшения объема необходимых вычислений принято делить изображение на части размером $M \times N$, а затем в каждом производится преобразование яркости – разбиение изображения на отдельные блоки - «плитки» [1,5,10] (рис. 1.9, рис.1.10):




Рис. 1.9 Разбиение изображения на отдельные блоки («плитки»)



Рис. 1.10. Оригинал (слева) и обработанное (справа) методом адаптивной локальной эквализации изображения с разбиением.

Размеры области изначально подбирались эмпирически, затем появились работы с приблизительными начальными размерами областей, в зависимости от размера всего обрабатываемого изображения [11-14].

Тогда плотность распределения вероятности яркости изображения, или гистограмма, равна:

$$p(j) = \frac{n_j}{Z} \quad (1.14)$$

где

$p(j)$ – вероятность появления пикселя j -ой яркости,

n_j – количество пикселей j -го уровня на изображении,

Z – общее количество пикселей.

Плато гистограммы — это ограничение по количеству пикселей каждой из яркостей, выбранных на гистограмме изображения. Все пиксели выше плато T суммируются и затем добавляются к яркости пикселей. Гистограмма с плато T равна:

$$P_T(k) = \begin{cases} P(k), P(k) \leq T \\ T, P(k) > T \end{cases} \quad (1.15)$$

где $P_T(k)$ - вероятность появления пикселя с ограничением по количеству пикселей T , k - координата пикселя обрабатываемого изображения.

Достоинства:

Простота реализации, вычислительная дешевизна ($O(N)$, где N — количество пикселей).

Недостатки:

Усиление шума: НЕ усиливает шум вместе с сигналом, особенно в ИК-изображениях с низким ОСШ. Это связано с тем, что НЕ не делает различий между сигналом и шумом; он просто перераспределяет уровни интенсивности в зависимости от их частоты встречаемости. Области с преобладающим шумом будут иметь растянутый диапазон интенсивности, что сделает шум более заметным. Типичное усиление шума для НЕ составляет 20-30% при ОСШ < 25 дБ.

Потеря деталей: НЕ может скрывать тонкие детали в областях, которые изначально имели низкую, но значимую контрастность. Это особенно проблематично в ИК-изображениях, где небольшие перепады температур могут иметь решающее значение для обнаружения и идентификации объектов.

Неестественный вид: НЕ может создавать изображения, которые выглядят неестественно или искусственно, особенно если исходная гистограмма имеет резкие пики или впадины. Это может затруднить интерпретацию человеком и снизить эффективность последующих алгоритмов компьютерного зрения.

Не подходит для ИК: Поскольку HE не учитывает физические свойства ИК-излучения и особенности формирования ИК-изображений, он не подходит для данного приложения.

2. CLANE (Contrast Limited Adaptive Histogram Equalization):

CLANE основывается на АНЕ, добавляя ограничение контрастности для уменьшения усиления шума. Это достигается путем ограничения гистограммы каждой локальной области перед вычислением CDF.

Ограничение гистограммы.

$$h_clip(i) = \min(h(i), \beta * \langle h \rangle) \quad (1.16)$$

где:

- $h(i)$ - исходная гистограмма
- β - параметр ограничения контраста
- $\langle h \rangle$ - средняя высота бина [1,5]

Интерполяция (необязательно используется): Чтобы смягчить артефакты блоков, часто используется билинейная интерполяция. Для пикселя, расположенного в (x, y) , его новая интенсивность вычисляется как взвешенное среднее преобразованных интенсивностей из четырех соседних областей обработки:

$$I_{new}(x, y) = w1 * T1(I(x, y)) + w2 * T2(I(x, y)) + w3 * T3(I(x, y)) + w4 * T4(I(x, y)) \quad (1.17)$$

где:

$T1, T2, T3$ и $T4$ — функции преобразования четырех соседних областей обработки,

$w1, w2, w3$ и $w4$ — веса интерполяции, которые зависят от положения пикселя относительно центров области обработки.

Достоинства:

Локальная адаптивность: Повышает контрастность локально, адаптируясь к изменениям освещения и содержимого сцены.

Уменьшенное усиление шума: Механизм ограничения ограничивает усиление контрастности, предотвращая чрезмерное усиление шума.

Улучшенное визуальное качество: Как правило, дает более естественные результаты, чем глобальная НЕ или базовая АНЕ.

Недостатки:

Артефакты блоков (уменьшены, но присутствуют): Даже при интерполяции некоторые артефакты блоков все еще могут быть видны, особенно при высоких пределах ограничения. Серьезность этих артефактов зависит от размера области обработки. Большие области обработки ($> 64 \times 64$) приводят к более заметным артефактам, потому что локальная адаптация менее точна. Меньшие области обработки (например, 8×8) уменьшают артефакты, но увеличивают вычислительные затраты.

Выбор параметров: Выбор размера области обработки и предела ограничения (β) имеет решающее значение. Оптимальные значения зависят от содержимого изображения, уровня шума и приложения. Универсальной оптимальной настройки не существует.

Вычислительная сложность: Сложность алгоритма CLAHE составляет $O(N \log N)$.

3. Retinex:

Retinex-теория основана на модели зрительного восприятия человека. Она пытается разделить изображение на две составляющие: освещенность (медленно меняющееся освещение) и отражательную способность (внутренние свойства объекта). Цель состоит в том, чтобы улучшить составляющую отражательной способности, которая считается независимой от освещения.

а) Одномасштабный Retinex (SSR):

$$R(x, y) = \log(I(x, y)) - \log(I(x, y) * G(x, y)) \quad (1.18)$$

где:

- $I(x, y)$ - входное изображение
- $G(x, y)$ - гауссовское ядро
- $R(x, y)$ - компонента отражения логарифмическая разность [15-16]

б) Многомасштабный Retinex (MSR):

$$R(x, y) = \sum [w_k * (\log(I(x, y)) - \log(I(x, y) * G_k(x, y)))] \quad (1.19)$$

где:

- w_k - весовые коэффициенты
- G_k - гауссовские ядра с разными σ_k
- $R(x, y)$ взвешенная сумма логарифмических разностей [15-18]

Недостатки:

Ореолы: Методы Retinex подвержены артефактам "ореолов". Эти ореолы проявляются в виде светлых или темных полос вокруг резких краев. Они вызваны ошибками в оценке компоненты освещенности. Резкий край (который является свойством отражательной способности) часто ошибочно интерпретируется как изменение освещенности, что приводит к неправильной оценке освещенности и, следовательно, к ореолу в компоненте отражательной способности.

Чувствительность к параметрам: Производительность Retinex зависит от выбора параметров (например, размера и количества гауссовых ядер в MSR).

Цветовые сдвиги: Retinex, даже многомасштабный, может вносить в сцену нереалистичные цветовые сдвиги [8,17,18].

4. Методы на основе вейвлет-преобразований:

Вейвлет-методы разлагают изображение на различные частотные поддиапазоны с использованием вейвлет-преобразований. Повышение контрастности обычно достигается путем изменения вейвлет-коэффициентов в этих поддиапазонах. Это обеспечивает локализованную и многомасштабную обработку контраста.

Часто для оценки частот применимо вейвлет-преобразование (например, дискретное вейвлет-преобразование - DWT) к изображению, разложив его на коэффициенты аппроксимации (низкочастотные) и детализации (высокочастотные).

Модификация коэффициентов: Измените коэффициенты детализации. Это может включать:

- Пороговая обработка: Подавление малых коэффициентов (часто связанных с шумом).
- Масштабирование: Усиление коэффициентов для повышения контрастности.
- Нелинейное отображение: Применение нелинейной функции к коэффициентам.

Обратное вейвлет-преобразование: Реконструируйте улучшенное изображение, используя модифицированные коэффициенты.

Многомасштабное вейвлет-преобразование:

$$g(x,y) = \sum w_i * T_i(f_i(x,y)) \quad (1.20)$$

где:

- w_i - весовые коэффициенты
- T_i - преобразования на разных масштабах
- $f_i(x,y)$ - компоненты разложения [19]

Выбор базисной функции вейвлета (например, Хаара, Добеши, Симлетов) влияет на производительность [19-22].

Хаар: Простой и вычислительно эффективный, но может вносить блочные артефакты [24].

Добеши: Более гладкий, чем Хаар, что приводит к меньшему количеству артефактов, но более сложный в вычислительном отношении. Различные вейвлеты Добеши (db2, db4, db8 и т. д.) имеют разную длину и свойства гладкости [23].

Симлеты: Похожи на Добеши, но более симметричны.

Недостатки:

- Настройка параметров: Выбор вейвлет-базиса, уровней разложения и стратегии модификации коэффициентов требует тщательной настройки.
- Вычислительные затраты: Вейвлет-преобразования вычислительно затратны, особенно для нескольких уровней разложения.
- Артефакты: Неправильный выбор параметров может привести к артефактам, таким как звон или размытие [23].

1.2.3. Нейросетевые подходы

Сверточные нейронные сети (CNN) для улучшения изображений: CNN особенно хорошо подходят для обработки изображений благодаря своей способности изучать пространственные иерархии признаков. Они могут быть обучены сквозным образом для повышения контрастности, часто используя архитектуру, подобную U-Net [24] со связями пропуска для сохранения деталей, представляет собой значительный прогресс в сверточных сетях для сегментации биомедицинских изображений. Благодаря всестороннему увеличению данных она решает ключевые задачи.

1. Сверточные нейронные сети (CNN):

Deep Retinex-Net

Подсеть Decom-Net разделяет исходное изображение на отражающую часть, независимую от освещения, и на гладкую часть, связанную со структурой. На этапе обучения используются пары изображений с низким и нормальным освещением, на этапе тестирования — только изображения с низким освещением. На рисунке 1.11 схема совместного использования cnn и алгоритма ретинекс. Изображения разбиваются на фон и детали нейронной сетью, далее обрабатываются исходя из теории ретинекса.

Декомпозиция изображения мультипликативная модель:

$$I = R * L \quad (1.21)$$

где: I - входное изображение, R - компонента отражения, L - компонента освещенности [25]




Рис. 1.11. Архитектура Deep Retinex-Net

Во время обучения не нужно предоставлять точные значения отражающей части и освещения. В сеть встраиваются только необходимые знания, в том числе о согласованности отражающей части и гладкости карты освещения.

2. Генеративно-состязательные сети (GAN):

GAN состоят из двух сетей: генератора (который создает улучшенные изображения) и дискриминатора (который пытается отличить реальные улучшенные изображения от сгенерированных изображений). Этот состязательный процесс обучения может привести к впечатляющим результатам, но GAN, как известно, трудно обучать. В целом это класс алгоритмов машинного обучения, которые используются для генерации новых данных, похожих на исходные. На рисунке 1.12 схемы архитектуры GAN при работе с изображением.




Рис. 1.12. Архитектура обучения GAN

Шаги, которые проходит GAN:

- Генератор получает случайное число и возвращает изображение.
- Это сгенерированное изображение подается в дискриминатор наряду с потоком изображений, взятых из фактического набора данных.
- Дискриминатор принимает как реальные, так и поддельные изображения и возвращает вероятности, числа от 0 до 1, причем 1 представляет собой подлинное изображение и 0 представляет фальшивое.

EnlightenGAN

комбинированная функция потерь:

$$L_{total} = L_{adv} + \lambda_1 L_{pixel} + \lambda_2 L_{percep} + \lambda_3 L_{smooth} \quad (1.22)$$

где: L_{adv} - состязательная потеря,

L_{pixel} - пиксельная потеря,

L_{percep} - перцептивная потеря,

L_{smooth} - потеря гладкости [25-27]

Нестабильность обучения — генератор и дискриминатор могут выходить из равновесия, что ухудшает качество генерируемых данных. Потребность в больших объёмах данных — для обучения GAN нужны значительные вычислительные ресурсы [28-29].

3. Гибридные подходы:

Сочетают в себе традиционные методы обработки изображений с нейронными сетями.

CLAHE + CNN:

Использование CLAHE в качестве этапа предварительной обработки с последующим использованием CNN для удаления артефактов и дальнейшего улучшения.

Последовательное применение

$$I_{\text{final}} = \text{CNN}(\text{CLAHE}(I_{\text{input}})) \quad (1.23)$$

где: I_{input} - входное изображение

- I_{final} - конечный результат [27]




Рис. 1.13. Пример гибридного подхода для медицинских изображений

CLAHE-CNN применялась для выявления признаков рака груди. В этом случае CLAHE используют для предварительной обработки изображений, а CNN — для их классификации [30].

Vision Transformers (ViTs)

В последние годы архитектура Transformer [31], изначально разработанная для обработки естественного языка, нашла применение и в области компьютерного зрения. Vision Transformers (ViTs) показали многообещающие результаты в различных задачах обработки изображений, включая улучшение изображений при слабом освещении.

Процесс работы ViTs включает несколько этапов:

1. **Обработка патчей.** Модель анализирует взаимодействия между патчами, что позволяет ей сосредоточиться на важных частях изображения.
2. **Финальное предсказание.** Выходы из весовых коэффициентов и полученные от синтезируемых данных используется для классификации или прогнозирования желаемого результата.

ViTs используют механизм самовнимания, который позволяет моделировать зависимости между удаленными частями изображения. Это особенно полезно для улучшения изображений при слабом освещении, где глобальный контекст важен для восстановления деталей.

Преимущества ViTs:

- **Моделирование дальних зависимостей:** ViTs используют механизм самовнимания, который позволяет моделировать зависимости между удаленными частями изображения. Это особенно полезно для улучшения изображений при слабом освещении, где глобальный контекст важен для восстановления деталей [31].
- **Адаптивность:** ViTs могут адаптироваться к различным типам изображений и условиям съемки.

Механизм самовнимания:

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T / \sqrt{d_k})V \quad (1.24)$$

где:

- Q - запросы
- K - ключи
- V - значения
- d_k - размерность ключей [32]

Недостатки ViTs:

- **Вычислительная сложность:** ViTs, как правило, более вычислительно сложны, чем CNN.
- **Требования к данным:** ViTs обычно требуют больших наборов данных для обучения.

Ограничения нейросетевых подходов:

1. Требования к данным:

- Необходимость большого набора данных (>10,000 изображений)
- Проблема переобучения при недостатке данных

2. Вычислительная сложность:

- $O(n^2)$ для операций свертки
- Высокие требования к памяти
- Время обработки >5с на CPU [32]

1.3. Критический анализ методов применительно к обработке малоконтрастных изображений

Существующие методы, описанные в 1.2, обладают рядом недостатков, ограничивающих их эффективность при обработке малоконтрастных изображений, особенно в условиях, характерных для ИК-съемки и встраиваемых систем:

1.3.1. Недостаточная эффективность при сильном шуме

Многие методы, в особенности глобальные (НЕ, линейное контрастирование), усиливают шум наравне с полезным сигналом. В ИК-изображениях, где ОСШ изначально низкое, это приводит к значительному ухудшению качества. CLAHE частично решает проблему за счет ограничения контраста, но фиксированный порог неоптимален для разных уровней шума.

Количественная оценка усиления шума различными методами:

$$NSR_out = k * NSR_in \quad (1.25)$$

где: NSR_out - отношение шум/сигнал после обработки,

- NSR_in - исходное отношение шум/сигнал
- k - коэффициент усиления шума (>1 для большинства методов) [31]

1.3.2. Потеря мелких деталей

Глобальные методы, а также локальные (АНЕ с большими окнами, Retinex) могут размывать или подавлять мелкие текстуры и границы объектов, что критично для задач обнаружения. В ИК-изображениях малые перепады температур могут нести важную информацию, и их потеря недопустима.

Количественная оценка сохранения деталей(градиентов):

$$DR = \sum |\text{grad}(I_{\text{out}})| / \sum |\text{grad}(I_{\text{in}})| \quad (1.26)$$

где:DR - коэффициент сохранения деталей

- grad() - оператор градиента.

1.3.3. Возникновение артефактов обработки

Локальные методы (CLAHE, Retinex, вейвлет-преобразования) порождают артефакты (блочность, ореолы, звон), ухудшающие визуальное качество и мешающие работе алгоритмов компьютерного зрения.

Классификация основных типов артефактов:

Блочность

- Метод: CLAHE (Contrast Limited Adaptive Histogram Equalization).
- Причина: Разбиение изображения на локальные регионы (области обработки) для адаптивного улучшения контраста. На границах области обработки возникает резкий перепад яркости из-за независимой обработки каждого блока.
- Проявление: Изображение выглядит разделенным на квадратные блоки с заметными границами, особенно в однородных областях (например, небо).

Ореолы

- Метод: Алгоритмы Retinex (например, MSRCR — Multiscale Retinex with Color Restoration).
- Причина: Некорректное разделение освещения и отражательной способности объекта. Переусиление контраста на границах яркостных переходов.
- Проявление: Светлые или темные полосы вокруг контрастных объектов (например, вокруг деревьев на фоне неба).

Шум квантования

- Метод: Глобальные методы сжатия или понижения битности (например, уменьшение цветовой палитры).

- Причина: Ограничение количества цветов или уровней яркости приводит к потере плавных градиентов.
- Проявление: Появление "пятнистости" или полос в областях с плавными переходами (например, градиенты неба).

Ложные контуры

- Метод: Нейросетевые методы (например, алгоритмы повышения разрешения, сжатия или стилизации).
- Причина: Ограниченная глубина цвета, ошибки в восстановлении текстур или артефакты обучения нейросетей.
- Проявление: Появление неестественных линий или "ступенек" в областях с плавными изменениями яркости (например, на коже в портретах)

1.3.4. Высокая вычислительная сложность

Многие современные методы, особенно нейросетевые, требуют значительных вычислительных ресурсов (GPU /ПЛИС), что неприемлемо для встраиваемых систем с ограниченными ресурсами (космические аппараты, БПЛА). Даже CLaNE может быть вычислительно затратным при малых размерах окон.

Сравнительная оценка вычислительной сложности:

HE: $O(N)$

CLaNE: $O(N \log N)$

Retinex: $O(N \log N)$

CNN: $O(N * K^2 * C^2)$ где:

- N - количество пикселей
- K - размер ядра свертки
- C - количество каналов

1.3.5. Проблемы выбора параметров обработки

Большинство методов требуют ручной настройки параметров (размер окна, порог ограничения в CLaNE, параметры Retinex, вейвлет-базис). Оптимальные

значения зависят от характеристик изображения, шума, освещенности. Фиксированные параметры неоптимальны для всех сценариев.

Основные параметры, требующие настройки:

1. Размер окна в локальных методах(*идеальный размер окна*):

$$W_{opt} = f(H_{local}, \sigma_{noise}, Scale_{features}) \quad (1.27)$$

2. Порог ограничения контраста в CLAHE:

$$T_{opt} = g(SNR, Content_type, Target_contrast) \quad (1.28)$$

Отсутствие учета частотных характеристик изображения при локальной обработке. Большинство существующих локальных методов (CLAHE, Retinex) оперируют непосредственно с интенсивностями пикселей, игнорируя частотный состав локальных областей. Это может приводить к неоптимальному усилению контраста, потере деталей или усилению шума.

Существующие методы, как правило, не учитывают наличие окклюзий, которые вносят резкие изменения интенсивности и нарушают локальную статистику, ухудшая работу алгоритмов, так как не учитывают изображения соседних кадров и соседних датчиков, в отличие от разработанного алгоритма.

1.3.6. Нерешенные проблемы и вызовы

1. **Разработка адаптивного метода**, автоматически подстраивающего параметры обработки (размер окна, степень ограничения контрастности, параметры нейросетевой модели) к локальным свойствам изображения (уровень шума, наличие деталей, окклюзии) и условиям съемки (освещенность, дальность).

2. **Создание легковесной нейросетевой архитектуры**, пригодной для реализации на ПЛИС в реальном времени, и обеспечивающей эффективное подавление шума и артефактов без потери мелких деталей.

3. **Разработка методов, устойчивых к окклюзиям** или способных их обнаруживать и компенсировать.

4. **Достижение баланса** между повышением контрастности, подавлением шума, сохранением деталей и минимизацией артефактов.

5. Разработка методов, учитывающих специфику ИК-изображений (температурную зависимость, неоднородность чувствительности детекторов, атмосферные эффекты).

На рис. 1.13 типы алгоритмов обнаружения объектов на изображении [1, 6].




Рис. 1.13. Алгоритмы обнаружения объектов в автоматических устройствах.

Предложенные методы могут быть применены и к инфракрасным системам визуализации.

В таблице 1.1 сравнение методов контрастирования.

Таблица 1.1. – Сравнение методов контрастирования

Метод	Принцип	Преимущества	Ограничения	Типичные приложения	Вычислительная сложность
Контрастно-ограниченное адаптивное выравнивание гистограммы (CLAHE)	Локальное выравнивание гистограммы с ограничением контраста	Улучшение локального контраста, ограничение усиления шума, уменьшение артефактов на границах	Более сложная реализация по сравнению с HE, требует настройки параметров (размер плитки,	Медицинская визуализация, подводная фотография, низкая видимость	Средняя

			предел отсечения)		
Многомасштабный Retinex (MSR)	Взвешенная сумма результатов SSR в разных масштабах	Лучший баланс между сжатием динамического диапазона и цветопередачей по сравнению с SSR	Может приводить к цветовым искажениям, требует выбора нескольких масштабов	Улучшение контраста и цветопередачи в различных условиях освещения	Высокая
Метод	Принцип	Преимущества	Ограничения	Типичные приложения	Вычислительная сложность
Многомасштабный Retinex с восстановлением цвета (MSRCR)	MSR с дополнительным шагом восстановления цвета	Улучшение контраста и цветопередачи с уменьшением цветовых искажений	Может инвертировать цвета в насыщенных изображениях, требует настройки дополнительных параметров	Улучшение контраста и цветопередачи изображений, не соответствующих предположению о «сером мире»	Высокая
Сверточные нейронные сети (CNN)	Обучение сложным отображениям между изображениями и с низким и высоким контрастом	Высокая эффективность, способность к изучению сложных признаков, адаптивность к различным задачам	Требуют больших объемов данных для обучения, значительных вычислительных ресурсов, интерпретируемость может быть затруднена	Улучшение изображений с низкой освещенностью (подводных, медицинских)	Очень высокая (обучение), высокая (вывод)

1.4. Методы оценки качества обработки изображений

Для оценки эффективности методов улучшения малоконтрастных изображений используются различные критерии, которые можно разделить на следующие группы:

1.4.1 Критерии визуальной оценки

1. Экспертная оценка (MOS - Mean Opinion Score):

$$MOS = (1/N) * \sum Score_i \quad (1.29)$$

где:

- N - количество экспертов
- Score_i - оценка i-го эксперта по шкале 1-5 [1, 33]

2. Парное сравнение:

$$P(A>B) = N_{AB} / (N_{AB} + N_{BA}) \quad (1.30)$$

где:

- P(A>B) - вероятность предпочтения метода А методу В
- N_{AB} - количество предпочтений А перед В [33,34]

1.4.2 Объективные метрики качества

Метрики с эталоном

1. PSNR с учетом особенностей восприятия:

Широко используемая метрика, которая количественно определяет отношение максимальной возможной мощности сигнала к мощности искажающего шума.

Однако PSNR не всегда хорошо коррелирует с воспринимаемым визуальным качеством, поскольку он чувствителен к общим различиям в интенсивности, но менее чувствителен к структурным искажениям. Потому возьмём его за основу добавив в него модификации согласно исследованиям учитывая особенности человеческого зрения

$$PSNR_{HVS} = 10\log_{10}(MAX^2/MSE_{HVS}) \quad (1.31)$$

Где MSE_{HVS} – среднеквадратичная ошибка, которая учитывает характеристики человеческого зрения [35].

2. Многомасштабный SSIM:

SSIM это более релевантная с точки зрения восприятия метрика, чем MSE или PSNR. Он сравнивает локальные паттерны интенсивностей пикселей, которые были нормализованы по яркости и контрасту. Он основан на идее, что человеческая зрительная система очень чувствительна к структурной информации.

$$MS\text{-}SSIM = \prod [l_j(x,y)]^{\alpha_j} * [c_j(x,y)]^{\beta_j} * [s_j(x,y)]^{\gamma_j} \quad (1.32)$$

где j - уровень масштаба [36]

Метрики 1 и 2 могут неадекватно отражать локальные изменения контрастности, которые имеют решающее значение для обнаружения объектов.

Локальные меры контрастности, такие как контраст Михельсона, могут использоваться для количественной оценки контрастности в определенных интересующих областях:

$$C_Michelson = (I_max - I_min) / (I_max + I_min) \quad (1.33)$$

Где I_max и I_min — максимальная и минимальная интенсивности в локальном окне [37]. Эта мера особенно полезна для оценки улучшения краев и мелких деталей.

В контексте данной диссертации, где рассматриваются малоконтрастные ИК-изображения, использование уточненной формулы (1.33) является более обоснованным, поскольку объекты интереса (например, люди или транспортные средства) часто имеют более высокую температуру и, следовательно, большую яркость, чем фон. Кроме того, формула (1.33) позволяет учесть влияние фона на пороговый контраст, что особенно важно при работе в условиях низкой освещенности и/или при наличии атмосферных помех.

Энтропия: Энтропия изображения измеряет количество информации в изображении. Более высокая энтропия обычно указывает на большее количество деталей и потенциально более высокую контрастность. Однако шум также увеличивает энтропию, поэтому это не самостоятельная метрика для улучшения низкой контрастности. Энтропия (H) рассчитывается как:

$$H = - \sum p(i) * \log_2(p(i)) \quad (1.34)$$

где $p(i)$ — вероятность того, что пиксель имеет уровень интенсивности i [1, 5].

Спектральная мощность шума: Оценка уровня шума в различных частотных диапазонах, если есть данные о принимаемом сигнале.

Безэталонные метрики:

Оценивают качество изображения на основе статистических свойств естественных изображений.

- **BRISQUE:**

$$Quality = f(MSCN_features, Product_features) \quad (1.35)$$

где $MSCN_{\text{средний нормированный контраст}}$ [38-42]

- **NIQE:**

$$D = \sqrt{(\mu_1 - \mu_2)^T * ((\Sigma_1 + \Sigma_2)/2)^{-1} * (\mu_1 - \mu_2)} \quad (1.36)$$

где μ и Σ - параметры модели естественных изображений [43-44]

На основе идей по статистическим свойствам изображений и энтропии в изображении разработана своя методика анализа качества, приведённая в диссертации.

1.4.3 Методы оценки эффективности алгоритмов компьютерного зрения

1. Точность обнаружения:

Доля правильно обнаруженных объектов.

Точность (precision) и полнота (recall):

$$\text{Precision} = TP / (TP + FP) \quad (1.37)$$

$$\text{Recall} = TP / (TP + FN) \quad (1.38)$$

где:

- TP –верные положительные
- FP –ложно положительные
- FN –ложные отрицательные [45].

2. F-мера:

Гармоническое среднее между точностью (precision) и полнотой (recall), что делает её сбалансированной метрикой для оценки качества бинарной классификации [46].

$$F1 = 2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (1.39)$$

3. Mean Average Precision (mAP):

Более полные метрики, учитывающие точность и полноту при различных порогах уверенности.

Метрика для оценки производительности моделей обнаружения объектов. Она представляет собой единый комплексный показатель, который суммирует способность модели правильно идентифицировать и находить объекты для различных классов и уровней доверия.

Расчёт mAP включает в себя несколько этапов, обеспечивающих надёжную оценку эффективности модели для различных классов объектов и порогов обнаружения:

1. **Сортировка по степени доверия.** Для каждого класса объектов предсказания модели (обнаруженные ограничительные рамки) сортируются по баллам доверия, от самого высокого к самому низкому.
2. **Кривая точности-результата.** Для каждого класса строится кривая Precision-Recall. Эта кривая показывает соотношение точности и запоминания, рассчитанное при различных порогах доверия.
3. **Средняя точность (AP).** Средняя точность (AP) для одного класса рассчитывается как площадь под его кривой «точность-отзыв».
4. **Средняя точность (mAP).** mAP рассчитывается путём усреднения значений AP по всем классам объектов в наборе данных.

$$AP = \int p(r)dr \quad (1.40)$$

где $p(r)$ - точность при уровне пере повтора— r .

Особенности mAP:

Учитывает точность классификации (насколько правильно определён класс объекта) и точность локализации (насколько правильно размещена ограничительная рамка) для всех классов, определённых в обучающих данных.

Балансирует между компромиссом между нахождением всех релевантных объектов (recall) и гарантией того, что найденные объекты действительно правильные (precision) [47].

Более информативен, чем изолированное рассмотрение точности или запоминания, особенно в наборах данных с несколькими категориями объектов или несбалансированным распределением классов.

Более высокий показатель mAP обычно указывает на более надёжную и прочную модель обнаружения объектов.

1.5. Постановка задачи исследования.

Разработать адаптивный метод локального повышения контрастности малоконтрастных ИК-изображений, пригодный для реализации на встраиваемых системах (ПЛИС) в реальном времени, и превосходящий существующие методы по совокупности показателей качества (повышение контрастности, подавление шума, сохранение деталей, минимизация артефактов, вычислительная эффективность, устойчивость к окклюзиям) и пригодный для использования в обработке изображений для нейронных сетей.

1.5.1. Цель исследования

Основная цель: разработка адаптивного метода локального повышения контрастности малоконтрастных ИК-изображений, обеспечивающего:

1. Автоматическую настройку параметров.
2. Эффективное подавление шума.
3. Сохранение мелких деталей.

1.5.2. Задачи исследования

1. Разработать модифицированный алгоритм CLANE с динамическим выбором размера окна обработки на основе локальной энтропии и частотного состава изображения (с использованием ДКП).
2. Разработать адаптивный механизм ограничения контрастности, зависящий от оцененного уровня шума и частотной составляющей, анализируемой с помощью ДКП.
3. Спроектировать и реализовать легковесную архитектуру CNN для постобработки, оптимизированную для ПЛИС.
4. Разработать метод безэталонной оценки качества, основанный на анализе локальной энтропии и среднем нормированном контрасте (по аналогии с BRISQUE, NIQE).
5. Провести экспериментальное исследование на разнообразных наборах данных (включая ИК-изображения), сравнить с существующими методами, проанализировать влияние параметров и устойчивость к окклюзиям.

6. Проанализировать влияние параметров метода на работу нейронных сетей.
7. Разработать практические рекомендации.
8. Исследовать способы взаимного расположения датчиков цифровых изображений для комплексирования и минимизации потерь информации при формировании изображений.

Производительность для обработки в реальном времени:

Не менее FPS > 30 в разрешении 640x480 16 бит для сравнения с аналогичными работами [48-57].

1.5.3. Обоснование научной новизны

Предлагаемый метод отличается от существующих подходов следующими ключевыми аспектами:

1. Адаптивный выбор параметров:

Впервые предложен динамический выбор размера окна обработки на основе локальной энтропии и анализа частотного содержимого с помощью ДКП. Введено адаптивное ограничение контрастности, зависящее от уровня шума и частотной составляющей.

2. Комбинированный подход:

Предложена интеграция модифицированного алгоритма локального контраста с CNN для выбора параметров алгоритма АЛК, что позволяет объединить преимущества обоих методов: локальную адаптивность алгоритма локального контраста и способность CNN к обучению сложным нелинейным отображениям. Разработана архитектура CNN для постобработки, оптимизированная для ПЛИС.

3. Безэталонная оценка качества:

Разработан метод безэталонной оценки качества, позволяющий оценивать и оптимизировать работу алгоритма без необходимости использования эталонных изображений. Метод оценки качества, основан на локальной энтропии и среднем нормированном контрасте.

4. Реализация на ПЛИС:

Впервые предложена интеграция модифицированного CLANE, адаптивного управления экспозицией/усилением с настройкой всей системы и CNN для регулировки параметрами адаптивного локального контрастирования (АЛК), обеспечивающая высокое качество обработки в реальном времени на ПЛИС.

Выводы по главе 1

В результате проведенного анализа существующих методов повышения качества визуализации малоконтрастных изображений, а также изучения особенностей их применения в контексте обработки ИК-изображений и использования совместной обработки с использованием нейронных сетей, можно сделать следующие выводы:

1. Показана актуальность проблемы улучшения малоконтрастных изображений

Проблема малоконтрастных изображений является критически важной для широкого круга приложений, включая системы видеонаблюдения, медицинскую визуализацию, автономный транспорт, аэрокосмических и БПЛА. Низкая освещенность, атмосферные эффекты, шумы сенсоров и окклюзии значительно ухудшают качество изображений, затрудняя обнаружение, сопровождение и распознавание объектов.

2. Проведен анализ существующих методов

Глобальные методы (HE, гамма-коррекция, линейное контрастирование) просты, но неадаптивны, усиливают шум и могут приводить к потере деталей. Локальные методы (ANE, CLANE, Retinex, вейвлет-преобразования) более адаптивны, но могут вносить артефакты и требуют тщательного выбора параметров. Нейросетевые методы (CNN, GAN, Transformers) обладают высоким потенциалом, но требуют больших объемов данных для обучения, значительных вычислительных ресурсов и сложны в интерпретации.

3. ИК-изображения имеют специфические особенности, которые необходимо учитывать при разработке методов повышения контрастности:

температурная зависимость сигнала, неоднородность чувствительности детекторов (FPN), необходимость калибровки и коррекции атмосферных эффектов.

4. Человеческое зрение имеет особенности восприятия контраста, которые необходимо учитывать при разработке алгоритмов (полосы Маха, одновременный контраст, адаптация к яркости).

5. Обработка изображений с помощью локального контрастирования положительно влияет на работу нейронных сетей, повышая точность распознавания, снижая чувствительность к шуму, улучшая детализацию, обеспечивая стабильность при изменении освещения и уменьшая зависимость от размеченных данных.

6. Существующие методы не в полной мере удовлетворяют требованиям приложений, работающих в реальном времени и в условиях ограниченных ресурсов. Необходимы новые подходы, сочетающие адаптивность, эффективность, устойчивость к шуму и артефактам, а также возможность реализации на встраиваемых системах (ПЛИС).

Одним из ключевых принципов современной обработки изображений является многомасштабный анализ, позволяющий учитывать как локальные особенности, так и глобальный контекст сцены. Этот принцип находит отражение в различных подходах, включая фрактальный анализ, вейвлет-преобразования и нейросетевые модели, извлекающие признаки на разных уровнях абстракции [6, 25]. Объединение этих сильных сторон классических подходов и современных нейросетевых алгоритмов приводит к более надежным, адаптивным и потенциально интерпретируемым решениям для локальной регуляции контраста.

Чтобы увеличить контраст гибридным методом, требуется решение следующих задач:

- разработка алгоритма с адаптивным ограничением контраста и динамическим выбором размера окна обработки;
- применение CNN для автоматической настройки параметров контрастирования;

- интеграция хроматического контрастного веса, минимизирующего цветовые искажения;
- оптимизация метода для реализации в системах реального времени (включая программируемую логическую интегральную схему (ПЛИС));
- экспериментальное тестирование на различных наборах данных (ИК-изображения, аэрофотосъемка и т. д.);
- сравнение с существующими методами.

На основании изложенного в первой главе аналитического обзора, включающего: 1) принципы формирования и обработки малоконтрастных изображений, в том числе в ИК-диапазоне; 2) обзор и критический анализ существующих методов повышения контрастности; 3) анализ влияния обработки на эффективность нейросетевых методов; 4) рассмотрение особенностей зрительного восприятия, определены следующие основные направления дальнейших исследований и задачи диссертационной работы:

1. Разработка нового адаптивного метода локального повышения контрастности, сочетающего в себе преимущества CLAHE (локальная адаптивность, ограничение усиления шума) с:

- динамическим выбором размера окна обработки на основе локальной энтропии изображения;
- адаптивным ограничением контрастности, зависящим от уровня шума и частотной составляющей анализируемой DCT;
- легковесной CNN для выбора параметров обработки, подавляющей остаточные артефакты и шум.

2. Теоретическое обоснование предложенного метода, включающее:

- математическое описание алгоритма и его компонентов;
- анализ устойчивости и сходимости;
- оценку вычислительной сложности.

3. **Программно-аппаратная реализация** предложенного метода на ПЛИС, обеспечивающая работу в реальном времени с учетом ограничений по ресурсам и энергопотреблению.

4. **Разработка метода безэталонной оценки качества** обработанных изображений, позволяющего автоматически настраивать параметры алгоритма.

5. **Экспериментальное исследование** предложенного метода на разнообразных наборах данных, включающих:

- стандартные тестовые изображения;
- ИК-изображения, полученные в условиях, имитирующих реальные;
- изображения с окклюзиями.

6. **Сравнительный анализ** предложенного метода с существующими методами по объективным (PSNR, SSIM, локальный контраст, энтропия, BRISQUE, NIQE) и субъективным (экспертная оценка) метрикам качества, а также по эффективности решения задач компьютерного зрения (обнаружение объектов) и собственной методике, основанной на локальной энтропии и среднем нормированном контрасте как в BRISQUE, NIQE.

7. **Анализ влияния параметров** предложенного метода на работу нейронных сетей (точность, скорость).

8. **Разработка практических рекомендаций** по применению и настройке разработанного метода в различных приложениях (системы видеонаблюдения, медицинская визуализация, ИК-системы, воздушная съемка).

ГЛАВА 2. Теоретическое обоснование разработанного алгоритма

Разработан гибридный метод адаптивного локального контрастирования (АЛК), где CNN автоматически определяет оптимальные параметры (размер окна r , порог отсечения T_c). Входами CNN служат изображение и локальные характеристики: энтропия $H(x,y)$ (2.2), доля ВЧ-информации $RHF(x,y)$ (2.6), безэталонная оценка качества $E(x,y)$ (2.13). Архитектура включает ветви для регрессии параметров. Обучение CNN на >200 000 изображений (видимый/ИК диапазоны) направлено на минимизацию безэталонной метрики качества обработанного изображения [58].

Основа гибридного метода разработанный алгоритм локального контрастирования (АЛК) имеет несколько настраиваемых параметров:

- размер окна (динамический, ограниченный диапазоном $[r_{min}, r_{max}]$),
- порог отсечения гистограммы T_c ,
- коэффициенты в критериях, используемых для адаптации размера окна и порога отсечения.

Проанализировано, как выбор этих параметров влияет на качество выходного изображения.

2.1. Динамическое скользящее окно




Рис. 2.1. Скользящее окно по кадру

При максимальном размере окна (рис. 1) ($r_{\max} \rightarrow$ размер изображения) локальное контрастирование вырождается в глобальное: выходная яркость $I'(x,y)$ всех пикселей определяется глобальной функцией преобразования, рассчитанной по гистограмме всего изображения. Это максимизирует общий контраст, но теряет локальные детали. При минимальном окне ($r_{\min} = 0$) локальная гистограмма вырождается, и $I'(x,y) \approx I(x,y)$.

Если размер окна $r(x,y)$ кусочно-постоянен, то внутри области с $r(x,y) = r_0$ локальное преобразование $T\Omega r_0$ эквивалентно свёртке с пространственно-инвариантным оператором. $I'(x,y)$ зависит только от пикселей в окрестности $\Omega r_0(x,y)$ и не зависит от абсолютного положения (x,y) внутри области. Это преобразование непрерывно и монотонно, не создавая разрывов градиента [59].

На границе областей с разными размерами окон r_1 и r_2 соседние пиксели (x,y) и $(x+1,y)$ обрабатываются в окрестностях $\Omega r_1(x,y)$ и $\Omega r_2(x+1,y)$. Разность их выходных значений $|I'r_1(x,y) - I'r_2(x+1,y)|$ обусловлена различием гистограмм в этих окрестностях. При значительном перекрытии окон разность мала.

Для минимизации пограничного эффекта используется взвешенное объединение:

$$I'(x,y) = \alpha(x,y) \cdot I'r_1(x,y) + (1 - \alpha(x,y)) \cdot I'r_2(x,y), \quad (2.1)$$

где $\alpha(x,y)$ ($0 \leq \alpha \leq 1$) – весовой коэффициент, плавно изменяющийся вблизи границы.

Динамическое окно обеспечивает локально-адаптивное контрастирование. Плавное изменение $r(x,y)$ и взвешенное объединение минимизируют артефакты на границах. Существует непрерывный переход от I' при $r_{\min} = 0$ (нет обработки) к глобальному контрастированию при $r_{\max}$.

2.2. Адаптивный размер окна

Выбран размер окна $r(x,y)$ в каждой точке изображения (рис.2.2). При промежуточных размерах окна возникает компромисс: меньший радиус лучше сохраняет мелкие текстуры (усиливает их контраст), но повышает шум [60]. Предлагается использовать локальную энтропию, частотные характеристики и

результаты безэталонной оценки качества как количественные показатели, определяющие размер окна.




Рис. 2.2. Обработка изображения «скользящим окном» $\Omega_r(x,y)$

2.3. Локальная энтропия

Локальная энтропия $H(x,y)$ в окрестности пикселя (x,y) характеризует информационное разнообразие яркости пикселей в этой области.

Формула для расчета локальной энтропии Шеннона:

$$H\Omega_r(x,y) = \sum_{i=0}^N p_i \log(p_i) \quad (2.2)$$

где: p_i – относительная частота яркости i в окрестности $\Omega_r(x,y)$, i – уровни яркости [1, 5].

Функция локальной энтропии:

- Оценка неоднородности: Энтропия показывает, насколько разнообразны уровни яркости в локальной области.
- Минимальное значение ($H = 0$): Соответствует однородной области, где все пиксели имеют одинаковую яркость.
- Максимальное значение: Энтропия достигает максимума при равномерном распределении яркостей. Это можно доказать методом множителей Лагранжа:

Вывод через множители Лагранжа:

Для поиска максимума энтропии $H = - \sum p_i \log_2(p_i)$ при условии нормировки распределения $\sum p_i = 1$, используется функция Лагранжа:

$$L(p_0, \dots, p_{(L-1)}, \lambda) = - \sum_{i=0}^{L-1} p_i \log_2(p_i) + \lambda \sum_{i=0}^{L-1} p_i - 1 \quad (2.3)$$

Приравнявая частные производные L по p_i и λ к нулю, получаем:

$$\partial L / \partial p_i = - (\log_2(p_i) + p_i * (1 / (p_i * \ln(2)))) + \lambda = -\log_2(p_i) - 1/\ln(2) + \lambda = 0 \quad (2.4)$$

$$\partial L / \partial \lambda = - \sum_{i=0}^{L-1} p_i - 1 = 0 \quad (2.5)$$

Из уравнения (2.4) следует:

$$\log_2(p_i) = \lambda - 1/\ln(2).$$

Следовательно: $p_i = 2^{(\lambda - 1/\ln(2))} = C$ (константа).

Подставляя $p_i = C$ во второе уравнение (условие нормировки):

$$\sum_{i=0}^{L-1} C = 1$$

Получаем: $L * C = 1$, откуда $C = 1/L$.

Таким образом: $p_i = 1/L$ для всех i .

Таким образом, $p_i = 1/L$ (где L – число возможных уровней яркости), что и соответствует равномерному распределению) для всех уровней яркости i , при котором энтропия достигает максимального значения.

2.4. Частотный анализ

Для каждой части изображения выбираем параметры для контрастирования. Был модифицирован «оконный алгоритм эквализации». Ранее было показано, что использование разных параметров эквализации для отдельных частей изображения позволяет уменьшить количество артефактов и влияние шумов на качество выходного изображения [60-61].

В разных источниках для автоматической настройки параметров под сюжет изображений использовались:

- функции преобразования на основе сохранённого полного кадра [55];
- выделение отдельных мод гистограмм [53];
- локальные среднеквадратичные отклонения [52];
- вейвлет-преобразование с получением аппроксимирующих составляющих [20,21].

Сигналы в любой форме представления содержат определенную полезную информацию. Эта информация обычно присутствует в амплитуде сигнала (абсолютной или относительной), в частоте или в спектральном составе, в фазе или в относительных временных зависимостях нескольких сигналов [5].

Если сигнал, который необходимо оценить по его частотным характеристикам является периодическим, то одним из простых способов оценки является его разложение в ряд Фурье. Всякая периодическая функция времени $x(t)$, которая в пределах периода ее изменения T удовлетворяет условиям Дирихле, может быть представлена рядом Фурье в виде (2.6):

$$x(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} a_n \cdot \cos(n\omega_1 t) + b_n \cdot \sin(n\omega_1 t) \quad (2.6)$$

$$a_0 = \frac{2}{T} \int_{t_0}^{t_0+T} x(t) dt$$

$$a_n = \frac{2}{T} \int_{t_0}^{t_0+T} x(t) \cdot \cos(n\omega_1 t) dt$$

$$b_n = \frac{2}{T} \int_{t_0}^{t_0+T} x(t) \cdot \sin(n\omega_1 t) dt$$

При расчете коэффициентов ряда Фурье необходимо выбрать начальный момент времени периода интегрирования.

1. В случае, когда функция $x(t)$ удовлетворяет условиям нечетности, то коэффициенты a_n будут равны нулю.
2. В случае, когда функция $x(t)$ удовлетворяет условиям четности, то коэффициенты b_n будут равны нулю.

С помощью тригонометрических тождеств и преобразований, ряд может быть записан в виде:

$$x(t) = \frac{A_0}{2} + \sum_{n=1}^{\infty} A_n \cdot \cos(n\omega_1 t + \varphi_n);$$

где амплитуда A_n и фаза φ_n могут быть рассчитаны по формулам:

$$A_n = \sqrt{a_n^2 + b_n^2}$$

$$\varphi_n = \arg(a_n - jb_n) = -\arctg \frac{b_n}{a_n}$$

$$a_n = A_n \cos \varphi_n$$

$$b_n = A_n \sin \varphi_n$$

Для определения 2ДКП (двумерного представления дискретно-косинусного преобразования) используется формула (2.7)

$$S(p, q) = \lambda_p \lambda_q \sum_{m=1}^M \sum_{n=1}^N \left(F(m, n) \times \cos\left(\frac{\pi}{2N}(2m-1)(p-1)\right) \cos\left(\frac{\pi}{2N}(2n-1)(q-1)\right) \right) \quad (2.7)$$

где N, M - количество строк и столбцов,

F(m,n) - значение яркости пикселя в изображении,

n=0..N-1 – номер строки, m=0..M-1 – номер столбца,

0<p<N, 0<q<M,

$$\lambda_p \begin{cases} \frac{1}{\sqrt{M}}, p = 0 \\ \sqrt{\frac{2}{M}}, 1 \leq p < M - 1 \end{cases}$$

$$\lambda_q \begin{cases} \frac{1}{\sqrt{N}}, q = 0 \\ \sqrt{\frac{2}{N}}, 1 \leq q < N - 1 \end{cases}$$

Одним из свойств 2ДКП является разделимость, по которому 2ДКП можно выполнить через одномерные ДКП по строкам и столбцам [1].

На рис. 2.3 представлен пример разложения изображения в коэффициенты функции ДКП. В получившейся матрице коэффициентов низкочастотные компоненты расположены ближе к левому верхнему углу, а высокочастотные - справа и внизу.




Рис. 2.3. Пример реализации ДКП преобразования

На рис. 2.4 матрица 8*8 имеет 64 компонента ДКП, расположенных в матрице зигзагом. DC ($S_{0,0}$) - среднее значение по всем коэффициентам, AC($S_{0,1}$ - $S_{7,7}$) - высокочастотные коэффициенты.

0 $S_{0,0}$	1 $S_{0,1}$	5 $S_{0,2}$	6 $S_{0,3}$				
2 $S_{1,0}$	4 $S_{1,1}$	7 $S_{1,2}$					
3 $S_{2,0}$	8 $S_{2,1}$						
9 $S_{3,0}$							
							60 $S_{6,7}$
						59 $S_{5,7}$	61 $S_{6,6}$
					58 $S_{4,7}$	62 $S_{5,6}$	63 $S_{7,7}$

Рис. 2.4. Распределение частот ДКП.

Коэффициенты дискретно-косинусного преобразования V_{pq} можно рассматривать как весовые при каждой базовой функции. Для матрицы с размером 8×8 элементов существует 64 базовые функции [1]. (рис. 2.5)




Рис. 2.5. Базовые функции ДКП, которые получены для матрицы с размерами 8×8 элементов

Соседние «плитки» имеют близкие значения ДС, то есть являются коррелированными. Анализ соседних отношений коэффициента ДС к ВЧ компонентам «плиток» позволяет определить момент разделения их на отдельные зоны обработки.

Для анализа изображения введём «коэффициент размера» равный отношению $(S_{0,1} + S_{1,0})/S_{0,0}$, где компонента $S_{0,0}$ (DC), компонента $S_{0,1}$ (AC0)-первый высокочастотный компонент, $S_{1,0}$ (AC1) - второй высокочастотный компонент (рис. 2.1).

Размер части изображения ДКП изменяется автоматически под размеры деталей и переходов, различимость которых необходимо увеличить в соответствии с изменением сюжета изображений. На рис. 2.6. отображен пример преобразования яркости в коэффициенты ДКП.




Рис. 2.6. Яркости пикселей в окне ДКП слева и пример результатов значений справа

Таким образом, алгоритм адаптивного контрастирования имеет вид (2.8).

С помощью двумерного дискретного косинусного преобразования (ДКП) фрагмента изображения $I(x+i, y+j)$ размером $(2r+1) \times (2r+1)$ в окрестности $\Omega_r(x, y)$, где $-r \leq i, j \leq r$ [60].

Первый коэффициент ДКП представляет собой среднюю яркость в окне (ДК-компонента), а коэффициенты F_{uv} (коэффициенты в разложении) при больших значениях u и v соответствуют высокочастотным компонентам изображения (мелким деталям, резким перепадам яркости, шуму).

Введём $RHF(x, y)$ как функция оценки частот в локальной области.

Доля высокочастотной информации $RHF(x, y)$ оценивается как отношение энергии высоких частот к полной энергии в окне:

$$RHF(x, y) = \frac{(\sum_{u,v=1}^r (u,v) \in H |F(u,v)|^2)}{(\sum_{u,v=1}^r (u,v) \in \Omega |F(u,v)|^2)}, \text{ где:} \quad (2.8)$$

- u и v - индексы частот по горизонтали и вертикали соответственно

и $-r \leq u, v \leq r$,

- Ω - множество *всех* пар индексов (u, v) в пределах окна ДКП, т.е., $-r \leq u, v \leq r$.
- H - множество пар индексов (u, v) , соответствующих *высоким* частотам. Это множество определяется пороговым значением D : $H = \{(u, v) \mid u^2 + v^2 > D^2\}$.
- D – пороговое значение, определяющее границу между низкими и высокими частотами. Выбор D зависит от конкретной задачи и характеристик изображения. Для видимого спектра выбран $D = r/2$, что соответствует половине максимальной частоты в окне.
- $|F(u, v)|^2$ - квадрат модуля коэффициента ДКП, представляющий собой энергию соответствующей частотной компоненты.

Выбор D зависит от размера максимального окна $r_{\max}$ обработки и максимальной частоты фона. Выбрано $D = r/2$, что соответствует половине максимальной частоты в обрабатываемом окне. Рассмотрим варианты адаптации начальных настроек для «автоматического алгоритма контраста» ИК-изображений большой разрядности (16 бит) (рис.2.7)




Рис. 2.7 –Слева оригинал, справа обработанное ИК изображение.

Оценивание «алгоритма адаптивного контрастирования» с учетом локальных сюжетных особенностей ИК- изображения произведено сравнением различных вариантов локальных областей, в которых оценивается частотная составляющая.

Приведённые в таблице 2.1 результаты показывают, что количество дефектов уменьшается в 1,6 раза (для ДКП 16*16). Также «алгоритм адаптации», при учитывании особенностей ИК-изображений, обеспечивает существенное увеличение точности обнаружения (для ДКП 32*32) [60].

Таблица 2.1. – Сравнение обработки изображений с оценкой по ДКП

Сравниваемый параметр	Метод обработки			
	Метод Clahe	Карта ДКП 2*2	Карта ДКП 16*16	Карта ДКП 32*32
Отношение ложных срабатываний к верно определённым объектам	0.127	0.081	0.06	0.0021
BRISQUE	50	68	81	77
Возможность автоматической настройки, первичных установок	нет	да	да	да

2.5. Безэталонная оценка качества

Обработка изображений с целью повышения визуального качества (дешифрируемости объектов) связана с желаемым повышением четкости и контраста. С точки зрения методов обработки эти два направления реставрации изображений опираются на линейные и нелинейные методы фильтрации [1, 62, 63]. Примыкает к этому направлению обработки изображений их сжатие для передачи по цифровому каналу связи. Учет нестационарности изображений приводит к концепции локально-адаптивной обработки изображений [62-63], т.е. к целесообразности их обработки независимо в каждом выбранном фрагменте. Размеры таких фрагментов определяются типовыми интервалами корреляции сигналов (размерами типовых объектов). На начальном этапе кодирования изображений в стандартах JPEG, MPEG использовалось раздельная обработка для фрагментов (блоков) размера 8×8 пикселей, позже, по мере увеличения четкости изображений (и, как следствие, интервалов корреляции сигналов) и удешевления аппаратных средств цифровой обработки, размеры типового фрагмента стали выбирать в виде блока 16×16 пикселей [65]. Краевые области изображений также отделяют, исходя из размеров интересующих объектов [18–19]. Во многих приложениях линейная фильтрация для повышения четкости (апертурная коррекция, методы которой восходят к фильтрации Колмогорова–Винера по критерию минимума среднеквадратической ошибки) и нелинейная фильтрация для контрастирования изображений производятся независимо. При этом методы

контрастирования традиционно опираются на выравнивание гистограмм сигналов, что рассмотрено в [1, 6]. «Эталонное сравнение» – сравнение изображения с идеальным образцом. Методы оценки эталонности могут варьироваться в зависимости от конкретной задачи или области применения, но обычно они включают в себя сравнение структуры, цветовых характеристик, резкости и других параметров изображения. «Безэталонное сравнение» – оценка качества изображения без явного стандарта для сравнения, основывается на статистических характеристиках изображения, восприятию человека или других методах анализа, не требующих эталона.

Для учета артефактов и общего качества обработки используется модифицированная безэталонная метрика, основанная на подходах естественных сцен (NIQE и BRISQUE) [66-68], но адаптированная к специфике задачи локального контрастирования. Изображение $I'(t)$ (результат обработки) разбивается на локальные области P_k (рис. 2.8).




Рис. 2.8. Разбиение изображения на локальные области для оценки искажений.

Для каждой области P_k вычисляются:

Средний нормированный контраст $C(i,j)$:

$$C(i, j) = \frac{I(i, j) - \mu(i, j)}{\sigma(i, j) + 1}, \quad (2.9)$$

где $\mu(i, j)$ – математическое ожидание яркости, вычисляемое с использованием весовой функции $W(i, j)$, представляющей собой круговое нормальное распределение:

$$\mu(i, j) = \sum_{i=1}^M M_{k=M} \sum_{j=1}^H H_{k=H} W(i, j) * I(i, j), \quad (2.10)$$

$$W(i, j) = \frac{1}{2 * a} \exp \left(-\frac{i^2 + j^2}{2} * S^2 \right), \quad (2.11)$$

S – стандартное отклонение (в оригинальном тексте $S=2$). $\sigma(i, j)$ – дисперсия яркости в окрестности (i, j) :

$$\sigma(i, j) = \sqrt{W(i, j) * (I(i, j) - \mu(i, j))^2}. \quad (2.12)$$

Коэффициент искажения γ :

$$\gamma = \frac{\left| \left(\frac{\sigma_1}{\sigma_2} \right) - \sigma_3 \right|}{\max \left(\left(\frac{\sigma_1}{\sigma_2} \right), \sigma_3 \right)}, \quad (2.13)$$

где σ_1 – стандартное отклонение распределения дисперсии центрального сегмента области, σ_2 – максимальное стандартное отклонение яркости соседних сегментов (слева и справа от центрального), σ_3 – стандартное отклонение яркости всего блока.

Величина искажения K :

$$K = (1 - \gamma) * \sigma_3^2 * I(\sigma_3 > T), \quad (2.14)$$

где

T – порог, определяющий заметность искажений,

γ – коэффициент искажения,

σ_3 – дисперсия всего блока,

$I(\sigma_3 > T)$ – индикаторная функция (равна 1, если $\sigma_3 > T$, и 0 в противном случае).

Итоговая оценка качества изображения E вычисляется как взвешенное среднее обратных величин искажений по всем пикселям:

$$E = \frac{(\sum_{k=1}^H K) + C_1}{(N + C_1)} \quad (2.15)$$

Где:

Е- итоговая оценка качества изображения,

C_1 - константа для устранения неопределённости (деления на 0), выбираем $C_1=1$,

К-величина искажения изображений в локальной области ($P_k = 16 \times 16$ пикс.),

N- количество областей,

H- количество пикселей.

Разработанный алгоритм безэталонной оценки качества изображений основан на глубоком понимании восприятия визуальной информации человеком. Он учитывает то предположение, что человеческое внимание сосредотачивается на отдельных локальных деталях изображения, играющих ключевую роль в его восприятии. Новый метод оценки качества изображений сегментирует изображение на локальные области, выделяя активные, заметные части и отделяя их от менее важных областей. Этот подход позволяет сосредоточиться на оценке только тех частей изображения, которые действительно влияют на его качество и восприятие. Таким образом, разработанный алгоритм представляет собой важный шаг в направлении создания более точных и эффективных методов оценки качества изображений [69].

Алгоритм обеспечивает адаптивный выбор размера окна, стремясь удерживать локальную энтропию и долю высоких частот на заданном уровне, а также учитывая качество обработки на предыдущем кадре и предотвращая появление артефактов у границ.

2.6. Ограничение контраста

Локальное гистограммное преобразование – нелинейный оператор. В однородной области с небольшим разбросом яркостей ограничение действует как повышение контраста, близкое к нормализации диапазона на весь выходной диапазон L . Если в окне (рис. 2) $\Omega_r(x,y)$ разброс значений яркости $\Delta I(x,y) = \max(I(x,y) \text{ в } \Omega_r) - \min(I(x,y) \text{ в } \Omega_r)$ значительно меньше L ($\Delta I(x,y) < L$)), то малые флуктуации яркости δI (соответствующие шуму) могут быть усилены примерно в фактор $L/\Delta I(x,y)$.

Ограничение контраста задается порогом T_c , снижает коэффициент усиления до величины, пропорциональной $(L-1)T_c/|\Omega_r|$, где $|\Omega_r|$ - количество пикселей в окне. Чем меньше размер окна (и, следовательно, меньше ΔI), тем больше потенциальный коэффициент усиления шума без ограничения. Слишком малое окно приводит к заметному усилению шума на выходе, а слишком большое – сглаживает и шум, и детали изображения.

Уменьшение порога T_c (более жесткое отсечение гистограммы) приводит к более мягкому воздействию. В пределе $T_c \rightarrow 0$ локальные гистограммы становятся практически равномерными, и усиление контраста минимально. В пределе $T_c \rightarrow \infty$ (отсутствие отсечения) ограниченное воздействие переходит в обычное адаптивному гистограммному выравниванию. Таким образом, T_c регулирует компромисс между усилением контраста и подавлением шума. В разработанном алгоритме $P_{\max}$ (отношение T_c к максимальной высоте гистограммы) выбирается в диапазоне 0.01–0.1 (1–10%).

Введение ограничения T_c обеспечивает липшицевость (ограничение) преобразования. Это означает, что существует константа K , такая, что для любых двух уровней яркости i и j в пределах окна $\Omega_r(x,y)$ выполняется неравенство:

$$|T(i) - T(j)| \leq K|i - j|, \quad (2.16)$$

где $K < \infty$ и определяется значением $T_c/|\Omega_r|$.

В классической гистограммной эквализации (без ограничения) константа K может быть очень большой, особенно в однородных областях изображения. Благодаря T_c локальные трансформации становятся устойчивыми.

2.7. Обеспечение использования нейросетевой модели

Нейросеть способна аппроксимировать нелинейные преобразования яркостей, выполняемые разработанным алгоритмом и решать задачу регрессии параметров алгоритма. CNN, фактически, выполняет многомасштабный анализ, извлекая признаки на разных уровнях абстракции. Это обеспечивает более контекстно-зависимое применение этих алгоритмов.

Согласно теореме Цыбенко (универсальной аппроксимации), любая непрерывная функция на компактном подмножестве конечномерного пространства может быть сколь угодно точно приближена нейронной сетью с одним скрытым слоем и достаточно большим числом нейронов [70].

Выбрана функция активации ELU (экспоненциальная линейная функция):

$$\text{ELU}(z) = \{ z, \text{ если } z \geq 0 \quad (2.17)$$

$$\{ \alpha(\exp(z) - 1), \text{ если } z < 0 \quad (2.18)$$

ELU (как и Leaky ReLU) решает проблему "умирающих нейронов", характерную для ReLU (Rectified Linear Unit, $f(x) = \max(0, x)$), когда нейроны перестают обучаться из-за нулевого градиента при отрицательных входных значениях. ELU и Leaky ReLU имеют ненулевой градиент при $x < 0$, что обеспечивает лучшую сходимость и предотвращает "затухание" нейронов. При этом ELU и Leaky ReLU достаточно просты в вычислении, что важно для встраиваемых систем [58].

Архитектура сети смаской эволюционно прошла вариант маски на основе по частоте к маске по градиентам с оценкой CNN: три последовательных слоя. Первый слой извлекает простые локальные признаки (градиенты яркости, контуры – аналоги фильтров Собеля), второй слой комбинирует эти признаки в более сложные (например, различает типы текстур или шум), а третий слой формирует выходную яркость пикселя и корректирует параметры алгоритма локального контрастирования.

В модель включена пропускная (короткая) связь – прямое добавление входного сигнала к выходу. Это позволяет сети легко реализовать тождественное преобразование (если для какого-то фрагмента изображения оптимально не изменять яркость) и повышает устойчивость обучения, облегчая прохождение градиента через сеть. Математически выход сети с одним скрытым слоем и пропускной связью можно записать как:

$$y = x + W2 * \varphi(W1 * x + b1) + b2, \quad (2.19)$$

где x – входное значение (яркость пикселя),

y – выходное значение,

$W1$ и $W2$ – матрицы весов первого и второго слоев,

$b1$ и $b2$ – векторы смещений, ϕ – нелинейная функция активации (ELU). Если оптимально $y \approx x$, сеть может достичь этого, занулив веса $W1$, $W2$ и смещения $b1$, $b2$, оставив только пропускную компоненту x .

Использование 3 слоев с 1 коротким соединением представляет собой компромисс между способностью аппроксимировать сложные функции и способностью хорошо работать на новых данных, не переобучаясь на тренировочном наборе.

Интеграция алгоритма в нейросетевой подход позволяет обучать параметры модели (веса и смещения) на данных, получая целевую функцию, связанную с качеством обработки изображений.

Входами CNN служат само изображение, а также рассчитанные для него локальные характеристики: энтропия $H(x,y)$ (2.2), доля ВЧ-информации $RHF(x,y)$ (2.8), и безэталонная оценка качества $E(x,y)$ (2.15), полученная на предыдущем шаге или для исходного изображения.

2.8. Обоснование адаптации алгоритма к ИК-изображениям

Под адаптацией алгоритма понимается распределение интенсивностей (яркостей) пикселей в ИК-изображениях, которая моделируется как смесь двух распределений, соответствующих фону и объектам интереса.

Окна, целиком лежащие внутри фоновой области, будут растягивать гистограмму ограниченно (благодаря ограничению), а окна, расположенные на границе между объектом и фоном, будут усиливать контраст именно между объектом и фоном [71].

Адаптация алгоритма для ИК-изображений включает в себя следующие основные моменты:

Размер окна: В среднем, размер окна выбирается большим, чем для изображений в видимом диапазоне, чтобы охватить больший контекст и учесть более плавные изменения яркости, характерные для ИК-изображений. Минимальный размер окна, увеличили, чтобы избежать чрезмерного усиления мелкого шума, который часто присутствует в ИК-данных.

Ограничение контраста: Для доминирующего фонового кластера гистограммы ограничение контраста устанавливается более строгим, чтобы предотвратить появление артефактов и чрезмерное усиление шума. Для малочисленных объектов ограничение контраста выбрано более мягким, так как их усиление важно для обнаружения и распознавания, и при этом не приводит к значительному увеличению общего уровня шума.

Многоуровневая обработка: Алгоритм применяется отдельно к высокочастотной компоненте изображения (деталям) и к низкочастотной компоненте (глобальным градиентам температуры объектов), чтобы одновременно усилить контуры объектов и сохранить информацию о распределении их температуры.

Архитектура нейросетевой модели (рис.2.9):

1) Входной слой: принимает изображение в градациях серого или компоненты цветного изображения.

2) Общие сверточные слои: 3 сверточных слоев с фильтрами (количество которых составляет 32) и ядром 3×3 , с функцией активации ELU для извлечения общих признаков из изображения.

3) Ветвь регрессии параметров:

- сверточные слои с глобальным усреднением;
- полносвязные слои;
- линейный выходной слой для предсказания параметров АЛК.

4) Skip connections соединяют соответствующие слои энкодера и декодера. На выходном слое используется сверточный слой для предсказания 4 параметров.

Архитектура гибридной CNN для локального контрастирования




Рис. 2.9. Архитектура гибридной CNN для регулировки адаптивного локального контрастирования

Сеть состоит из нескольких сверточных слоев для извлечения признаков из входного изображения. Входными данными для сети являются само изображение $I(x,y)$, а также предварительно рассчитанные карты локальной энтропии $H(x,y)$, доли ВЧ-информации $RHF(x,y)$ и безэталонной оценки качества $E(x,y)$. Выходной слой сети регрессирует два ключевых параметра: $r_pred(x,y)$ и $Tc_pred(x,y)$, которые затем используются в алгоритме АЛК. Обучение сети направлено на минимизацию безэталонной метрики качества $E(x,y)$ обработанного изображения, что позволяет сети научиться подбирать параметры, приводящие к наилучшему визуальному результату и минимизации артефактов [57].

Обучение нейросетевой модели (таблица 2.1):

1) Прямой проход: Изображение -> Нейросеть -> 4 параметра -> АЛК -> Обработанное изображение.

2) Оценка качества: Обработанное изображение -> безэталонная оценка качества изображения -> Значение оценки.

3) Расчет функции потерь: Функция потерь = Значение безэталонной оценки качества изображения (среднее по батчу).

4) Обратное распространение: Вычисление градиентов функции потерь по весам CNN через backpropagation. Градиенты определяют направление изменения весов для минимизации функции потерь.

5) Обновление весов: Оптимизатор градиентный спуск обновляет веса CNN на основе градиентов для улучшения предсказания параметров АЛК, оптимизирующих значение безэталонной оценки.

Обучающая выборка

Для обучения гибридной сети использовался датасет из более чем 200 000 изображений, охватывающий видимый и ИК спектры, а также различные условия съемки. Данные разделены по спектральному диапазону.

Данные видимого Спектра (3500 пар):

– черно-белые (1920×1200):1000 пар (солнечно / пасмурно); центральная часть изображений без сжатия;

– черно-белые (1920×1200):1500 пар (с / без поляризационного фильтра); центральная часть изображений без сжатия;

– цветные (1280×1024 HSV используется V-канал):1000 пар для каждого фильтра ЖС17 (λ 490-2700нм), ОС12 (λ 540-2700 нм) и КС17 (λ 670-2800 нм) (цветные фильтры) (рис. 2.10).

Выборка использовала данные при съёмке при выборе фильтров из эксперимента по подбору параметров спектральных светофильтров, выбираемые из стандартного набора. В работе А. К. Цыцулина и др. «Твердотельные телекамеры накопление качества информации» обоснована и описана методика

экспериментального подбора параметров спектральных светофильтров. Фильтры выбраны из стандартного набора и обеспечивающих максимум отношения сигнал/шум в перепаде между объектом и фоном в зависимости от метеорологической дальности видимости. При этом, чем меньше МДВ, тем большую часть спектра в коротковолновой области должен подавлять оптимальный спектральный фильтр [3].




Рис. 2.10 Объекты на фоне неба с фильтрами: левый верхний без фильтра, правый верхний ЖС17, левый нижний КС17, правый нижний ОС12

Данные инфракрасного спектра (11500 изображений): 11500 изображений с NUC (коррекция неоднородностей матриц с двумя кривыми второго порядка); для изображений 1280×1024 использовалась центральная область 640×512 (16-битные изображения).

Для ИК и видимого диапазона были обучены две отдельные модели. Обучение проводилось на двух видеокартах NVIDIA Tesla K40X и заняло около 200 000 итераций, параметры обучения в таблице 2.2 [57].

Таблица 2.2. – Параметры обучения

Параметр	Значение	Обоснование
Эпохи	100	Обеспечивает сходимость без переобучения
Размер батча	99	Сбалансированное использование GPU
Learning rate	$1e-4 \rightarrow 1e-6$	Используется LROnPlateau
Оптимизатор	Градиентный спуск	Снижение переобучения, стабильность
Функция потерь	Комбинированная безэталонная	Универсальность, не требует разметки
Инициализация	Xavier Uniform	Оптимальна для ELU
Активация	ELU ($\alpha = 0,1$)	Предотвращает затухание градиента
Регуляризация	Dropout 0,3 (в полносвязных слоях)	Устойчивость к переобучению
Аугментации	Различие выборок данных	Повышение обобщающей способности
Набор данных, изображений без меток	> 3,500 видимого спектра > 11,500 ИК	Аэрофотосъемка 1920×1200 / 1280×1024, ИК кадры
Фреймворк	PyTorch + Albumentations	Быстрая отладка, кастомные трансформации

Обучение для видимого спектра: 100 эпох.

1. Размер батча: 99 изображений (равномерная выборка по 33 изображения из каждой подкатегории видимого спектра).
2. Оптимизатор: Стохастический градиентный спуск (SGD) обновляет веса CNN.
3. Начальная скорость обучения: 0,001 (скорость изменения коэффициентов слоев градиентного спуска).
4. Оценка качества: Качество обработанного изображения оценивается с помощью безэталонной метрики $E(x,y)$.
5. Расчет функции потерь: Функция потерь определяется как значение безэталонной оценки качества $E(x,y)$ (среднее по батчу), которую сеть стремится минимизировать.
6. Стратегия Learning Rate: Cosine annealing. Скорость обучения циклически изменяется по косинусоидальной функции, способствуя стабильности

сходимости и предотвращению локальных минимумов. Параметры cosine annealing (период цикла, минимальная и максимальная скорость обучения) были настроены эмпирически для достижения оптимальной сходимости.

7. Функция потерь: среднее значение безэталонной оценки качества по батчу.

Цель – минимизация функции потерь, т. е. улучшение качества изображения по собственной метрике безэталонной оценки качества.

В качестве функции активации в сверточных слоях используется экспоненциальная линейная функция (ELU), которая, в отличие от ReLU, позволяет получать и отрицательные выходные значения, что полезно для представления информации о контрасте. На выходе сети формируется вектор значений, полученных нейронной сетью. Параметры АЛК (Размер окна, порог, H , RHF, E), являются входами в ветвь регрессии, которая затем выводит r и T_s [57].

Выбор данных характеристик (H , RHF, E) обусловлен их способностью отражать локальную сложность, текстуру, уровень шума и общую структуру изображения, что критично для адаптации к нестационарным условиям видимости. Их непрерывность и дифференцируемость позволяют эффективно использовать их как для регрессии параметров (r , T_s) нейросетью, так и в качестве компоненты функции потерь при ее обучении.

Выводы по главе 2

В главе 2 представлено теоретическое обоснование разработанного алгоритма локального контрастирования, включающее:

При изменении размера окна $r(x,y)$ от $r_{\min} = 0$ (отсутствие обработки) до $r_{\max}$ (глобальное контрастирование) происходит непрерывный переход между локальной и глобальной обработкой. Внутри областей с постоянным r преобразование эквивалентно свёртке. На границах областей с разными r используется взвешенное объединение для минимизации артефактов: $I' = \alpha I'_1 + (1-\alpha)I'_2$. Оптимальный размер окна $r(x,y)$ определяется итеративно, минимизируя функционал, зависящий от локальной энтропии $H(x,y)$, доли высоких частот RHF(x,y) и безэталонной оценки качества предыдущего кадра $E(x,y)$:

Введение порога T_c (или P_{max}) обеспечивает липшицевость преобразования: $|T(i) - T(j)| \leq K|i - j|$, где K определяется $T_c/|\Omega_T|$ (рис.2.2). Это предотвращает чрезмерное усиление шума.

Разработанный алгоритм может быть аппроксимирован нейронной сетью с ELU-активацией и skip-связями, что позволяет обучать параметры модели на заданных данных. Локальная энтропия $H(x,y)$ является мерой информационной насыщенности и неоднородности яркости, что критично для выбора размера окна обработки.

Доля ВЧ-информации $RHF(x,y)$, полученная с помощью ДКП, отражает наличие мелких деталей и текстур, а также уровень шума, что напрямую влияет на оптимальную степень ограничения контраста T_c и размер окна r . Безэталонная оценка качества $E(x,y)$ позволяет сети ориентироваться на перцептивное качество и минимизировать артефакты, замыкая цикл адаптации.

Таким образом, разработанный адаптивный алгоритм локального контрастирования, основанный на динамическом окне, энтропийно-частотных критериях, безэталонной оценке качества и ограничении контраста, позволяет эффективно повышать контрастность изображений, минимизируя артефакты и учитывая локальные особенности. Параметры алгоритма (размер окна, порог ограничения) автоматически адаптируются к входным данным с применением нейронной сети.

ГЛАВА 3. Практическая реализация на ПЛИС обработки изображения малококонтрастных объектов в условиях ограниченной видимости

Целевая платформа – ПЛИС Xilinx Kintex-7 XC7K325T. **Алгоритм работы гибридного алгоритма** (структурная схема реализации алгоритма на ПЛИС (рис.3.1) [57]):

1. Входной интерфейс буферизует строку изображения в BRAM.
2. Данные после NUC (коррекции) параллельно идут на CNN (для параметров) и на расчет локальных характеристик.
3. Легковесная CNN передает начальные параметры (r - Размер окна, T_c - порог, значения H - энтропия, RHF - частотный, E - значение оценки качества кадра для алгоритма АЛК к которым следует стремиться при обработке. Архитектура: Три сверточных слоя (Conv2D) с небольшим количеством фильтров (32-64) и ядром 3×3 . Для реализации используются таблицы перекодировки, используется арифметики с фиксированной точкой.
4. Вычисляются локальные характеристики (энтропия, RHF , дисперсия) для обрабатываемой области строки.
5. АЛК использует параметры от CNN и локальные характеристики для оценки/эквализации яркости пикселя в адаптивном окне, расчет из (2.1) следует $r_target(x, y)$ (3.1) и коррекция y границ (3.2). Данные обрабатываются в блоках параллельно.
6. Уточняется яркость пикселя, и в конце кадра вычисляется безэталонная оценка качества (E). Безэталонная оценка (для следующего кадра): Вычислить $Q_prev(x, y)$ для каждой точки (x, y) на основе величины искажения K в соответствующей локальной области P_k (рис.3.1) обработанного изображения $I'(t)$.
7. Обработанные пиксели заполняют выходной буфер (BRAM) для вывода или передачи в ОЗУ.

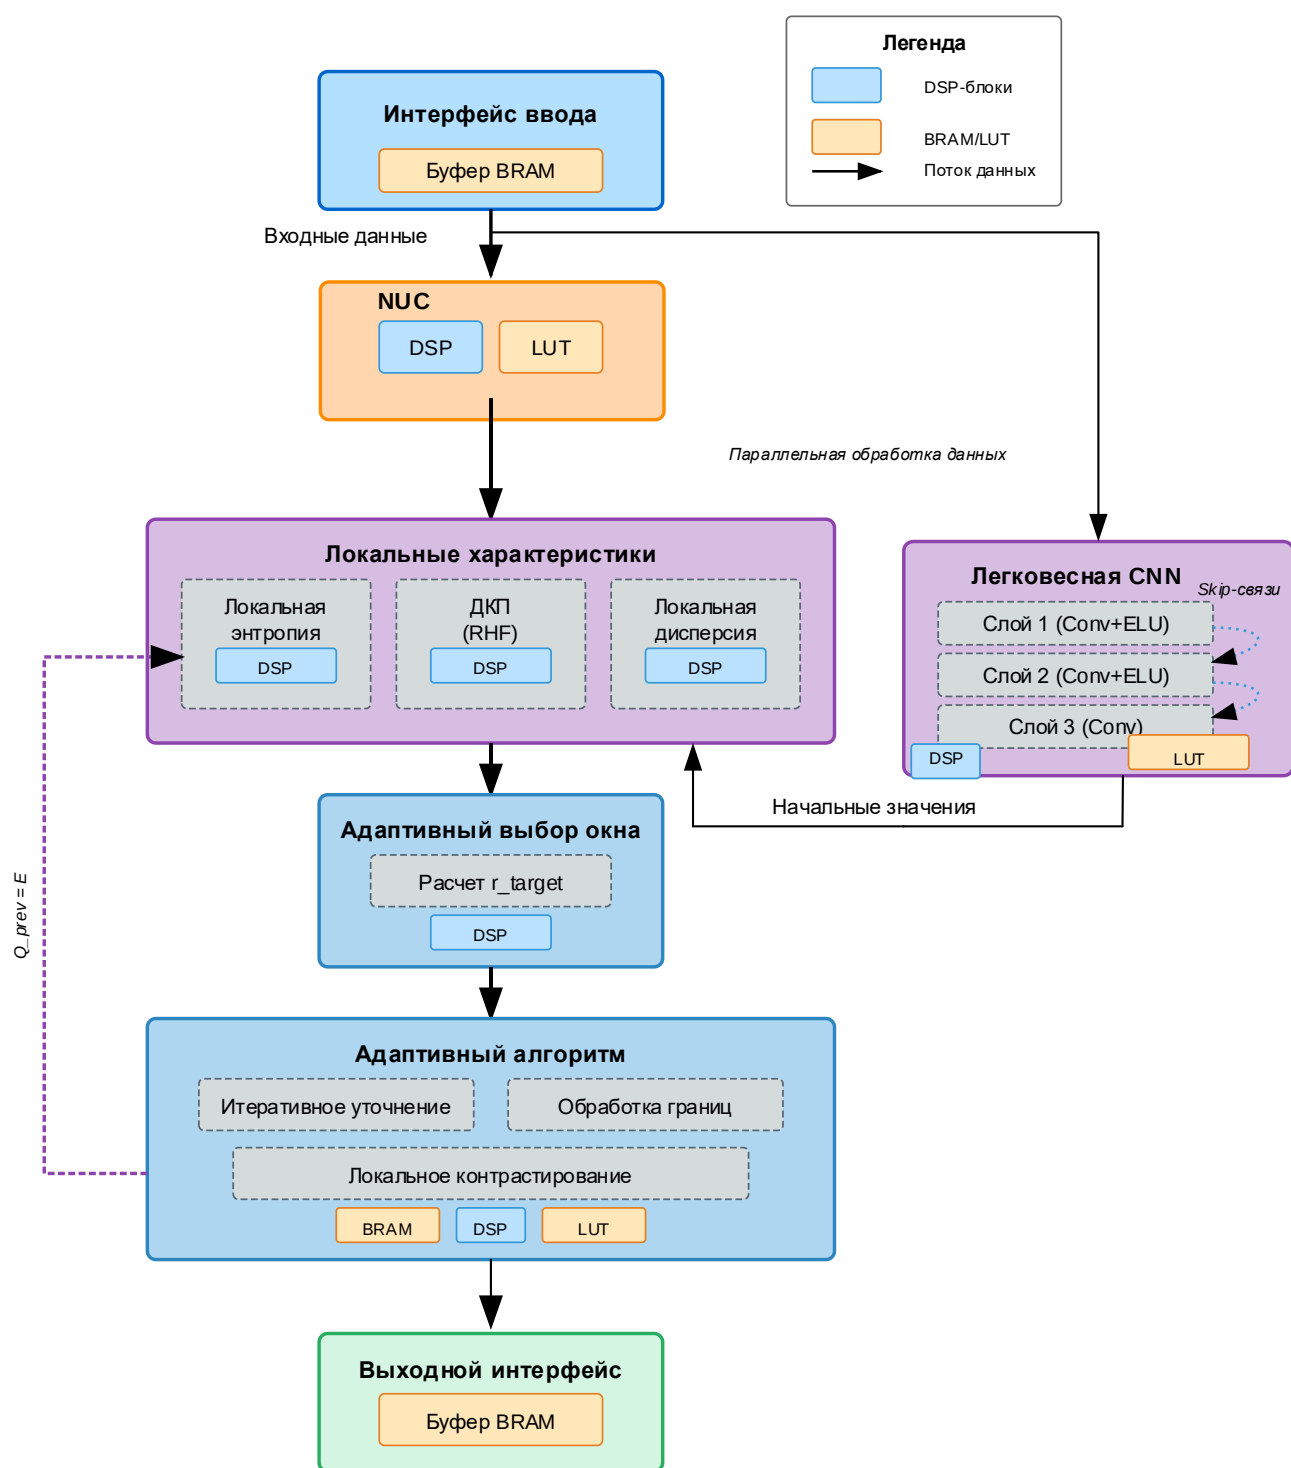


Рис. 3.1. Структурная схема реализации гибридного алгоритма на ПЛИС

Производительность: Алгоритм с CNN: >60 кадров/с для изображений 1920x1080. Упрощенный алгоритм (без CNN): >120 кадров/с для изображений 1920x1080. Упрощенная CNN: позволяет дополнительно увеличить производительность (при незначительном снижении качества обработки).

Потребление ресурсов: Менее 70% ресурсов ПЛИС (полный алгоритм), менее 40% (упрощенный алгоритм).

Энергопотребление: < 5 Вт. При $mAP = 0,4$ ошибка ε составляет не более 0,05 – это соответствует выборке из 20000 изображений (в 20 раз больше $1/0,05$). Ошибка ε , тестовая выборка $\geq 1/\varepsilon$.

Для экспертной оценки качества использовался метод парного сравнения согласно рекомендацией МСЭ-RBT.500-11(06/02) [34], в котором экспертам предлагалось выбрать изображение с лучшим контрастом из пары, включающей результат работы предложенного алгоритма и результат одного из следующих методов:

- CLaNE: с параметрами, указанными в оригинальной работе;
- Multi-Scale Retinex:

Предварительная обработка (коррекцию неоднородности сенсора).

Вычисление локальных характеристик: энтропии $H(x,y)$, доли высоких частот $RHF(x,y)$ (с использованием ДКП), дисперсии и оценки уровня шума.

Адаптивный Тс: локальное контрастирование с ограничением гистограммы и адаптивным размером окна.

Легковесная CNN: Устранение остаточных артефактов и шума и настройка начальных параметров АЛК.

Для настройки алгоритма под сюжет используется легковесная сверточная нейронная сеть (CNN), оптимизированная для аппаратной реализации на ПЛИС. Основные характеристики CNN:

Архитектура: Три сверточных слоя (Conv2D) с небольшим количеством фильтров (32-64) и ядром 3×3 .

Функция активации: ELU (Exponential Linear Unit) формулы (2.17-2.18)

Для реализации используются таблицы перекодировки, используется математические операции с фиксированной точкой.

Реализована обработка изображения "скользящим окном" с параллельной обработкой данных для всех слоёв одновременно.

Алгоритм адаптации размера окна:

$$r_target(x, y) = (1 - \beta) * [r_min + (r_max - r_min) * (\eta(x, y) + v(x, y)) / 2] + \beta * r(x, y) * (E(x, y) / 100) \quad (3.1)$$

где $\eta = (H_{max} - H) / H_{max}$, $v = 1 - RHF$, β – весовой коэффициент.

У границ изображения и областей с разной яркостью/сюжетом $r(x, y)$ уменьшается:

$$r(x, y) \leftarrow r(x, y) * (1 - \alpha * \|\nabla I(x, y)\| / \max_gradient) \text{ при } \|\nabla I(x, y)\| > \text{gradient_threshold} \quad (3.2)$$

Адаптивный выбор размера окна: расчет из (2.1) следует $r_target(x, y)$ (3.1) и коррекция у границ (3.2).

Вычисление локальных характеристик:

Локальная энтропия $H(x, y)$ (2.2).

Доля высоких частот $RHF(x, y)$ (2.8) с использованием ДКП. Коэффициент размера окна D по частоте в формуле (2.8) может быть настроен под сюжет.

Безэталонная оценка (для следующего кадра): Вычислить $Q_prev(x, y)$ для каждой точки (x, y) на основе величины искажения K в соответствующей локальной области P_k (рис.2.9) обработанного изображения $I'(t)$.

Гистограмма: Для каждого положения окна вычисляет гистограмму яркости пикселей. Гистограмма реализована с использованием блоков памяти ПЛИС (BRAM).

Для получения количественных значений результатов обработки изображений предложенным алгоритмом воспользовались проведением натурных испытаний согласно рекомендацией МСЭ-R BT.500-11 (06/02).

Проведено сравнение производительности разработанного алгоритма (включая варианты с CNN и упрощенной CNN) с известными аналогами на ПЛИС (Таблица 3.1 и 3.2).

Сравнение производительности и результаты

В таблице 3.1 и 3.2 приводится сравнение с аналогами.

Таблица 3.1 – Сравнение реализаций локального контраста на ПЛИС

Сравниваемый параметр	Метод обработки			
	Метод_1 <i>Agalya P.</i> , [48]	Метод_2 <i>Klupsch S</i> [49]	Метод_3 (один поток) <i>Грицкевич И. Ю.</i> <i>Виноградов А. С</i> [73]	Метод_4 (два потока) <i>[Грицкевич И. Ю.,</i> <i>Ерганжиев Н. А.</i> <i>2019[72]</i>
поток Мрiх/с, при максимальной частоте	61 (209.6Mhz)	62 (69 Mhz)	60.6 (200 Mhz)	118.19 (200 Mhz)
Частота кадров для разрешения 1920*1080	33 fps	33.3fps	29.224 fps	57 fps
Количество используемой памяти ПЛИС	(256+64)*10 Kb	16*18 KB	96*10kb	104*10kb
Количество логики (унифи- цировано LEs)	64246Les (32123 Luts) (640*480)	10723Les (4766) (640*480)	3500Les (1412 ALM) (1920*1080)	7000Les (2824 ALM) (1920*1080)

Таблица 3.2. – Сравнение алгоритмов по производительности обработки видео

Сравниваемый параметр	Метод обработки			
	Метод 1 <i>Kokofuta K.</i> , [50]	Метод 2 <i>Ali Reza</i> [51]	Метод по «плиткам» <i>Грицкевич И. Ю.</i> , <i>Ерганжиев Н. А.</i> <i>2019[72]</i>	Метод «скользящее окно» <i>Грицкевич И. Ю.</i> <i>,Ерганжиев Н. А</i> <i>. 2021[60]</i>
Максимальный поток <i>Мрiх/с</i>	61	6,2	118	133
Частота кадров в секунду	3,3	25	57	65
Количество памяти/разрешение изображения	320*10Кб (640*480)	16*18Кб (640*480)	104*10 Кб (1920*1080)	64*10 kb (1920*1080)
Сюжетная коррекция	нет	нет	нет	возможна

Коррекция окна и плато в реальном времени	нет	нет	возможна	возможна
---	-----	-----	----------	----------

Разработанный алгоритм превосходит аналоги по скорости обработки и ресурсоемкости, обеспечивая высокое качество изображения [61, 72]. Достигнуто 2х кратное увеличение производительности по сравнению с аналогичными реализациями. При оценке производительности с использованием нейронных сетей достигнуто уменьшение времени обработки в 20 раз по сравнению с аналогами, что подтверждено актом внедрения №2.

3.1. Особенности реализации для контрастирования изображений.

В отличие от классического CLAFE, где размер области обработки фиксирован, разработанный метод использует динамический подход.

Текстурированные области: Для областей с высоким уровнем детализации (текстуры, края) целесообразно использовать меньшие начальные размеры окрестности для более точного локального контрастирования.

Однородные области: Для однородных областей (с низким уровнем детализации) можно использовать большие начальные размеры окрестности для эффективного подавления шума и уменьшения вероятности появления артефактов.

Локальная энтропия как мера текстурированности: В качестве основной характеристики для адаптации используется локальная энтропия изображения, которая является мерой информационной насыщенности области. Высокая энтропия указывает на наличие большого количества деталей, низкая — на однородность.

Для учета частотного состава локальной области изображения, в дополнение к локальной энтропии, используется дискретное косинусное преобразование (ДКП). ДКП позволяет разложить сигнал на частотные компоненты, что дает информацию о наличии в области мелких деталей (высокие частоты) или однородных текстур (низкие частоты).

Размеры области и другие параметры определяются на основе анализа локальных характеристик изображения:

$$W(x,y) = \text{base_size} * K(x,y) \quad (3.3)$$

где:

- $W(x,y)$ - локальный размер окна
- $base_size$ - базовый размер (8×8 пикселей)
- $K(x,y)$ - коэффициент масштабирования [1]

В областях с высоким содержанием высоких частот (мелкие детали, текстуры) начальный размер окна должен быть меньше, чтобы сохранить эти детали. В областях с низким содержанием высоких частот (однородные области) начальный размер окна больше.

Коэффициент $K(x,y)$ определяется как:

$$K(x,y) = (1 + \alpha * \sigma(x,y) + \beta * H(x,y)) \quad (3.4)$$

где:

- $\sigma(x,y)$ - локальное стандартное отклонение
- $H(x,y)$ - локальная энтропия
- α, β - весовые коэффициенты

Использован $W_init = 64$, как компромисс между адаптивностью и вычислительной сложностью. В дальнейшем, в процессе обработки, этот размер уменьшен для отдельных пикселей

Для каждого пикселя (i, j) изображения вычисляется локальная энтропия $H_local(i, j)$ в окрестности размера $W_init \times W_init$. (2.2).

Суммирование ведется по всем возможным уровням яркости k (от 0 до $L-1$, где L — количество уровней яркости, 256 для 8-битного изображения).

Адаптивный параметр ограничения контрастности $\beta(i, j)$ зависит не только от уровня шума $\sigma_noise(i, j)$, но и от частотной составляющей локальной области, оцениваемой с помощью ДКП. Ограничение размера:

$$w_start(i, j) = \max(W_min, \min(W_max, w_start(i, j))) \quad (3.5)$$

- **Выбор параметров:**

- $W_min = 8$ выбран, чтобы обеспечить статистическую достоверность при расчете локальной энтропии.

- $W_{\max} = 64$ выбран как компромисс между адаптивностью и вычислительной сложностью.

$$\beta(i, j) = \beta_{\min} + (\beta_{\max} - \beta_{\min}) * \exp(-\gamma * \sigma_{\text{noise}}(i, j) - \delta * \text{RHF}(i, j)) \quad (3.6)$$

где: δ - параметр, регулирующий влияние частотной составляющей на параметр ограничения.

В областях с высоким содержанием высоких частот (мелкие детали) ограничение контрастности должно быть более строгим, чтобы предотвратить потерю деталей $\text{RHF}(x, y)$ из (2.8).

Дополнительные характеристики: Помимо локальной энтропии, для адаптивного выбора начальных параметров могут использоваться:

- **Локальная дисперсия:** Мера разброса значений яркости в окрестности пикселя. Высокая дисперсия указывает на наличие контрастных деталей.
- **Оценка уровня шума:** использована для регулировки параметра ограничения контрастности (см. главу 2).
- **Тип фона:** Информация о типе фона (небо, вода, лес, город) использована для предварительной настройки параметров алгоритма.

В предлагаемом методе, в отличие от классического CLAFE, который применяет преобразование яркости ко всему блоку целиком, функция преобразования применяется индивидуально к каждому пикселю изображения. Это обеспечивает более тонкую адаптацию к локальным особенностям изображения и уменьшает вероятность возникновения артефактов блочности. При этом, расчет функции преобразования по-прежнему основывается на анализе локальной окрестности пикселя, но эта окрестность динамически изменяется.

Оценка уровня шума

Для каждого пикселя (i, j) оценивается локальный уровень шума $\sigma_{\text{noise}}(i, j)$ в окрестности $w_{\text{start}}(i, j) \times w_{\text{start}}(i, j)$.

Для подавления шума используется анализ локальной статистики, которая используется для обратной ошибки в нейронной сети:

$$S(x, y) = \mu(x, y) + \lambda(x, y)(f(x, y) - \mu(x, y)) \quad (3.7)$$

где:


- $\mu(x,y)$ - локальное среднее
- $\lambda(x,y)$ - коэффициент усиления
- $f(x,y)$ - входное значение [4]

Если окрестность пикселя считается однородной (на основе анализа энтропии $H(2.2)$ и $RHF(2.8)$), то $\sigma_noise(i, j)$ можно оценить как стандартное отклонение яркости пикселей в этой окрестности.

Блочная оценка:

Разбить окрестность на мелкие блоки (3x3) и вычислить стандартное отклонение в каждом блоке. Затем взять медиану или среднее этих стандартных отклонений.

При обработке ИК-изображений (рис. 3.2) получаем:



а) исходная локальная часть



б) обработанное изображение

Рис. 3.2. Результат обработки зашумленного ИК изображения.

Адаптивное ограничение контраста вычисляется как:

$$T_c(x,y) = T_{base} * M(x,y) \quad (3.8)$$

где $M(x,y)$ - функция модуляции:


$$M(x,y) = 1 + \gamma * (E(x,y)/E_max)$$

$E(x,y)$ - локальная оценка краев

E_max - максимальная оценка краев

γ - параметр чувствительности

Метод оценки шума - стандартное отклонение в однородной области и блочная оценка [62, 71] были выбраны совместно из-за их устойчивости к выбросам, которые могут присутствовать в ИК-изображениях.



а) исходное малоконтрастное ИК изображение

б) обработанное ИК изображение

Рис. 3.3. Результат обработки ИК-изображений.

Использовались следующие условия наблюдения: 15 наблюдателей. Все эксперты радиоинженеры и исследователи радиотехнических систем, из них 6 женского пола. По возрастным группам следующее распределение: 6 человек от 21 до 26 лет, 5 человек от 30 до 36 лет, 4 человека от 50 до 65 лет. У 4-х человек близорукость у двух дальновзоркость. Все 15 имеют опыт работы с изображениями и ТВ-сигналами. Для оценки собран стенд (рис. 3.4), который для испытуемого выдавал 5 пар изображений исходных и обработанных разработанным алгоритмом, испытуемые эксперты могли управлять переключателем выдачи изображений.




Рис. 3.4. Стенд оценки изображений экспертами

По оценке изображений оценщикам были даны следующие вводные критерии оценки:

1. Оценка отсутствия искажений и артефактов на изображении по 100 бальной шкале, где 100 полное отсутствие;
2. Оценка контраста границ предметов (машин, деревьев, знаков, столбов ит.п.) относительно необработанного изображения по 100 бальной шкале;
3. Оценка яркости изображения по 100 бальной шкале;
4. Оценка цветности изображений по 100 бальной шкале, где 100 сохранение цветности как в исходном изображении с увеличением насыщенности;
5. Оценка четкости изображения по шкале от 1 до 10, где 1 - полное размытие, а 10 - максимальная четкость;
6. Оценка разрешения изображения искажения соотношения сторон, где 10 соотношение сторон не изменилось, 0 изменилось отношение ширины и высоты всего изображения;
7. Оценка резкости изображения по шкале от 0 до 5, где 5 - максимальное значение резкости;
8. Оценка зернистости изображения по шкале от 0 до 3, где 3 - минимальное значение зернистости;

9. Оценка уровня шума на изображении по шкале от 0 до 4, где 4 - минимальный уровень шума;

10. Оценка наличия структурной блочности в изображении (в виде структурной маскировки деталей изображения) 0 до 5, где 5 – отсутствие артефактов структурной блочности по двум направлениям (осям X и Y);

11. Оценка наличия яркостной блочности в изображении (в виде структурной маскировки деталей изображения) 0 до 5, где 5 – отсутствие яркостной блочности (в виде яркостной маскировки деталей изображения) 0– наличие артефактов структурной блочности по двум направлениям (осям X и Y);

12. Оценка наличия муара в изображении, 5 – отсутствие периодических смещений в изображении, 0 – наличие смещений, которые изменяют грани объектов.

Предварительно экспертам были продемонстрированные варианты искажений, указанные в критериях 1, 2, 10, 11, 12. Для этого использовались тренировочные последовательности, демонстрирующие диапазон и тип искажений, которые должны быть оценены, при этом демонстрационные изображения в этих последовательностях отличались от тех, что будут предложены в испытаниях.

После подготовки – производилось вычисление средней оценки $\bar{u}_{jkr}$, для каждой демонстрации:

$$\bar{u}_{jkr} = \frac{1}{N} \sum_{i=1}^N u_{ijkr} \quad (3.9)$$

где u_{ijkr} - оценка эксперта i для условия j ,

k -ой демонстрации, для r -х повторов демонстраций;

N :число экспертов [34].

Пары оценок (эталонного и испытываемого изображений) для каждого условия испытаний преобразовывал из измерений длины на бланке оценок в нормированные оценки и усреднял в графе Итог в таблице 3.4. Затем рассчитывал разности между оценкой в условиях эталонного и испытываемого изображения.

Не проводилась оценки доверия каждому эксперту и среднего отклонения при оценке эксперта, из-за ограничения по времени испытания.

Таблица 3.4. – С экспертной оценкой

№ эксперта изображение	№ критерия												Итог
	1	2	3	4	5	6	7	8	9	10	11	12	
1 Оригинал	97	11	29	18	3	10	1	0	0	0	0	0	0,17
Обработанное	38	89	90	85	6	9	5	2	4	5	5	5	0,97
2 Оригинал	99	9	18	22	3	9	0	0	0	0	0	0	0,2
Обработанное	36	89	90	85	6	7	5	3	4	5	5	5	0,97
3 Оригинал	95	7	27	26	3	9	1	0	0	0	0	0	0,2
Обработанное	33	83	86	85	6	7	5	2	4	5	5	5	0,97
4 Оригинал	99	8	29	23	3	9	0	0	0	0	0	0	0,2
Обработанное	35	91	86	85	6	8	5	3	4	5	5	5	0,97
№ эксперта/ изображение	№ критерия												Итог
	1	2	3	4	5	6	7	8	9	10	11	12	
5 Оригинал	98	11	19	27	3	10	0	0	0	0	0	0	0,2
Обработанное	36	92	80	79	6	10	5	3	4	5	5	5	0,97
6 Оригинал	95	8	30	18	3	9	0	0	0	0	0	0	0,2
Обработанное	34	78	87	85	6	7	5	3	4	5	5	5	0,97
7 Оригинал	94	8	30	21	3	9	0	0	0	0	0	0	0,2
Обработанное	40	85	93	85	6	8	5	3	4	5	5	5	0,97
8 Оригинал	94	11	24	25	3	9	0	0	0	0	0	0	0,2
Обработанное	38	87	84	85	6	10	5	3	4	5	5	5	0,97
9 Оригинал	97	10	27	22	3	10	0	0	0	0	0	0	0,2
Обработанное	37	78	80	85	6	10	5	3	4	5	5	5	0,97
10 Оригинал	96	10	30	30	3	10	0	0	0	0	0	0	0,2
Обработанное	36	80	90	85	6	10	5	3	4	5	5	5	0,97
11 Оригинал	99	7	29	28	3	10	0	0	0	0	0	0	0,2
Обработанное	34	86	91	85	6	10	5	3	4	5	5	5	0,97
12 Оригинал	97	8	24	22	3	10	0	0	0	0	0	0	0,2
Обработанное	33	80	78	85	6	10	5	3	4	5	5	5	0,97
13 Оригинал	95	10	22	26	3	10	0	0	0	0	0	0	0,2
Обработанное	33	78	85	79	6	10	5	3	4	5	5	5	0,97
14 Оригинал	94	9	18	23	3	10	0	0	0	0	0	0	0,2
Обработанное	37	95	81	91	6	10	5	3	4	5	5	5	0,97
15 Оригинал	98	7	29	25	3	10	0	0	0	0	0	0	0,2
Обработанное	36	85	90	93	6	10	5	3	4	5	5	5	0,97
Оригинал ср.	96,8	8,7	24,4	85	6	10	5	3	4	5	5	5	0,18
Обработанное ср	35,1	85,9	86,4	85	6	10	5	3	4	5	5	5	0,9

Разработанный алгоритм предобработки позволяет автоматически улучшить качество цветных изображений в 5 раз исходя из полученных результатов экспертной оценки.

3.2 Исследование зависимости размера области обработки от коэффициентов ДКП при контрастировании изображений.



Рис. 3.5. Адаптивный алгоритм на основе частотного параметра изображений.

После проведённых расчётов получены результаты адаптивной обработки изображения (рис. 3.6, рис. 3.7).



Рис. 3.6. Оригинал изображения.



Рис. 3.7. Результаты использования алгоритма контрастирования изображений.

Был использован безэталонный метод, с помощью которого оценивалось приближение к идеальному натуральному изображению локальных деталей изображения.

В качестве анализа работы по реализации алгоритма адаптивного контрастирования с учетом локальных сюжетных особенностей изображения

произведено сравнение различных критериев в оценке результатов. В таблице 3.5 отображена оценка локального контрастирования [68].

Таблица 3.5 Оценка алгоритма

Сравниваемый параметр	Метод обработки			
	Метод Clahe	Размер «плиток» 32*32	Размер «плиток» 2*2	Метод с «картой размера» «плиток»
Критерий оптимальности	0.07	0.0021	0.0015	0.0036
NIQE	7,8	7,1	6,9	9,5

Полученные результаты обработанных натуральных изображений тумана показали эффективность алгоритма обработки при оценке как по критерию оптимальности нахождения деталей на изображении, так и по автоматическому алгоритму безэталонной оценки.

Разработанный алгоритм обработки изображений позволяет получить данные с минимальной задержкой и высокой эффективностью последующей сегментации и обнаружения элементов в условиях ограниченной видимости. Алгоритм последовательности действий приведён на рис. 3.8.




Рис. 3.8. Алгоритм процесса обработки строки:

K_R — контраст, рассчитанный по входным данным;

G_R — рассчитанное число градаций;

K_l — контраст, полученный после обработки;

G_l — число градаций, полученное после обработки

Основные этапы выполнения данного алгоритма обработки строк:

1. Загрузка видео данных из внешней памяти, либо непосредственно из матрицы изображения в реальном времени (Пиксели изображения).

2. Параллельный расчёт размеров области обработки, кривых преобразования в этих областях по гистограммам, а также коэффициентов ограничений усиления.

Для цветных камер производится преобразование в формат HSV (один яркостный и два цветовых).

3. Сохраняется карта размеров, используемая для первого прохода, и увеличивается количество строк (максимальное), сохраняемых в соответствующих ячейках памяти ПЛИС. Сохраняется 8 строк изображения и в каждой из них производится разбиение на области, в которых производится вычисление ДКП-2. После вычисления принимается решение о необходимости разбиения на меньшие блоки по горизонтали. При близости коэффициентов размера (< 1), происходит слияние соседних областей для общей обработки.

4. Вычисляются коэффициенты ограничения усиления K и количества градаций G .

Это имеет решающее значение при оптимизации производительности. Высокие пороги G приводят к эффективному снижению шума, поскольку все гладкие поверхности на изображении будут заменены их проекциями, но неприятным побочным эффектом является то, что многие слабые текстуры будут классифицированы как гладкие и впоследствии не будут усилены. При выборе порога K необходимо также учитывать целевое качество всей системы. Предполагалось использование пороговых значений с оптимальным отношением. Эксперименты показывают, что подходящие значения для порога K лежат в диапазоне от 0,035 до 0,037 при использовании $B=16$ в качестве размера блока.

5. Сравнение производится с общими значениями градаций, полученными при обработке.

6. Выполняется чтение всех соответствующих компонент HSV изображения. И переход к обработке следующих строк в кадре [73].

Ниже показана схема работы алгоритма кадра, в который входит алгоритм обработки строки (рис. 3.9).




Рис. 3.9. Алгоритм цикла предобработки кадров

Для выполнения предобработки используется алгоритм циклический по горизонтали (по строкам), с «отзеркаливанием» недостающих строк.

При обработке происходит взаимное использование глобального и локального контрастирования.

Если нет необходимости в немедленной выдаче обрабатываемых изображений, наиболее эффективным оказался алгоритм с объединением описанных выше алгоритмов локальной обработки и глобального линейного растяжения яркости пикселей. Порядок обработки приведён на рис. 3.10.




Рис. 3.10. Алгоритм комбинированной обработки кадров

При комбинированном методе обработки используются те же действия с изображениями, что и с локальным контрастированием.

Применение комбинированных алгоритмов увеличивает время обработки изображения на чтение текущего кадра и анализ предыдущего [73-79].

Легковесная CNN для постобработки

Разработана легковесная сверточная нейронная сеть для подавления остаточных артефактов. Архитектура CNN включает:

1. Входной слой:

`Input(height, width, channels)`

2. Сверточные слои:

`Conv2D_1(filters=32, kernel_size=3x3, activation='ReLU')`

`Conv2D_2(filters=64, kernel_size=3x3, activation='ReLU')`

`Conv2D_3(filters=32, kernel_size=3x3, activation='ReLU')`

3. Выходной слой:

`Conv2D_out(filters=1, kernel_size=1x1, activation='sigmoid')`

Реализация алгоритма на ПЛИС представляет собой конвейерную структуру, в которой данные последовательно проходят через ряд функциональных блоков (рис. 3.1).

3.3. Особенности реализации алгоритмов контрастирования на ПЛИС

Для реализации на ПЛИС выбран алгоритм локального контрастирования, который не использует множество операций умножения с данными, и у которого операции деления с использованием данных можно преобразовать к делению степени 2 для оптимизации в ходе внедрения на ПЛИС. В качестве прототипа был взят алгоритм контраст-ограниченной локальной эквализации гистограмм.

Для того чтобы использовать алгоритм локального контрастирования (эквализации гистограмм), по отдельным областям с последующей билинейной интерполяцией, был построен конвейер для обработки кадров высокого разрешения с частотой минимум 25 кадров в секунду.

Для обработки цветных изображений, поступающих с камеры в RGB формате, содержащем три цветовых канала, изображение необходимо преобразовать в один из форматов, в котором выполнено разделение цветовой и

яркостной информации. Для черно-белого изображения такой проблемы не возникает ввиду наличия в нем только одного яркостного канала.

За условную единицу принят квадратный фрагмент изображения («плитка»), состоящий из W пикселей по высоте и ширине [72]. Структурная схема разработанного алгоритма представлена на рис. 3.11.




Рис. 3.11 Структурная схема реализации разработанного алгоритма

Ниже приведены основные этапы выполнения данного алгоритма:

1. Загрузка видео данных из внешней памяти, либо непосредственно с матрицы изображения в реальном времени в RGB формате (Пиксели изображения).
2. Для разделения яркостной и цветовой составляющих изображения выполняется преобразование RGB формата в пространство HSV (RGBtoHSV преобразователь), которое содержит три канала: один яркостной и два цветowych (оттенок и насыщенность).

3. Данные, размещенные в цветовых каналах, сохраняются в соответствующих буферах памяти ПЛИС [72-73].

4. Данные яркостной компоненты сохраняются во внутреннем буфере размером в длину строки кадра помноженную на количество строк (H) в двух «плитках» (принятых за минимальные).

5. При первом чтении из входного буфера (Память на ПЛИС) выполняется загрузка каждой «плитки» в конвейер обработки и расчёта гистограмм. Одновременно производится их усечение путем расчёта общего превышения над порогом, заданным в процентах от общего количества пикселей в каждой «плитке».

6. После расчета гистограмм для двух «плиток» вычисляются их кумулятивные функции распределения и функция трансформации [72]. Полученные результаты записываются в тот же самый буфер, где хранились гистограммы плиток. Затем осуществляется последовательное выполнение перечисленных операций над остальными «плитками» кадра. Полученные в результате расчета коэффициенты записываются в буферы, которые использовались ранее для расчёта гистограмм. Такой процесс носит название пространственной конвейеризации.

7. После расчета коэффициентов трансформации производится считывание значений пикселей «плиток» (третье чтение из входного буфера) с присваиванием им новых значений с учётом функции трансформации, а также с учётом положения данного пикселя относительно других. В зависимости от места взаимного расположения «плиток» выполняется один из трех вариантов интерполяции: билинейная, линейная или без интерполяции. С учётом того, что выходной буфер имеет размерность в H строк, вначале считываются $H/2$ строк, и только после расчёта коэффициентов для следующих «плиток» выдаются остальные строки. После прохождения первых H строк, данные выдаются сразу, как только рассчитываются коэффициенты четырех «плиток» (пиксели, для которых необходимо выполнить билинейную интерполяцию, могут быть рассчитаны только в том случае, если известны коэффициенты окружающих пикселей).

8. После выполнения необходимых преобразований производится запись полученных новых яркостных значений пикселей в канал яркости.

9. Выполняется чтение всех соответствующих компонент HSV изображения с последующим преобразованием в формат RGB.

Для увеличения скорости обработки изображения предложен вариант преобразования, при котором показанные выше блоки в устройстве делят принятые строки «плиток» на их количество (временная конвейеризация). Далее обработанные фрагменты необходимо сшить с перекрытием (одной «плитки» в ходе экспериментов оказалось достаточно). Ниже показана схема работы этого фрагмента алгоритма (рис. 3.12).




Рис. 3.12. Обработка изображения в два потока с перекрытием в одну «плитку»

Без штриховки обозначены области, для которых интерполяция не выполняется, штриховкой слева-направо показаны области линейной

интерполяции, штриховкой крест-накрест - области билинейной интерполяции. Области, заштрихованные точками (крайние области двух потоков, пересекающие друг друга) не используются, области с билинейной интерполяцией от разных потоков обозначены штриховкой в виде шахматного поля.

Два потока перекрывают строки кадра таким образом, что в местах их соприкосновения нет областей без билинейной интерполяции, обработанных в одном из потоков.

Разработанный алгоритм позволяет производить гибкую настройку реализуемой системы, а также даёт возможность параллельного использования нескольких блоков для обработки разных частей изображения и возможность обрабатывать широкий поток, не увеличивая частоту работы блока (рис. 3.13).




Рис.3.13. Результаты реализации локального контрастирования на ПЛИС:

- а) оригинальное изображение,
- б) пример эквализации отдельных областей (плиток) без интерполяции,
- в) результат применения контрастно ограниченной локальной эквализации после интерполяции при обработке в два потока.

Как было отмечено в главе 1.3, для реализации CLANE критичен выбор двух параметров: лимита среза и размера «плитки», которые обычно определяются пользователем вручную. В разработанном алгоритме эти параметры могут регулироваться в любых пределах (причём данные параметры возможно изменять в ходе обработки, то есть, существует возможность для авторегулирования и

подстройки под окружающие условия), ограниченных лишь памятью ПЛИС. Это позволяет адаптировать эти параметры под конкретное изображение и получить максимально детализированную картину [72-76]. В аналогичных работах размер «плитки» задаётся фиксированным (например, 64х64), что даёт преимущество в виде уменьшения количества операций над кадром, но за счёт потери качества.

Помимо этого, в разработанном алгоритме коэффициенты рассчитываются и применяются к одному и тому же кадру. Каждый кадр загружается в блок однократно, построчно и выдаётся там же. Поэтому для работы алгоритма не требуется наличия внешней памяти.

Развивая идею адаптации изображения в данной работе модифицирован алгоритм локальной эквализации гистограммы. Это позволило увеличить скорость вычисления и улучшить оцениваемые параметры контраста отдельных частей изображения, а также уменьшить количество артефактов, появляющихся от предобработки изображений.

Алгоритм обработки изображения методом эквализации гистограммы модифицируем, заменив анализ изображения по частям - «плиткам», оценкой каждого пикселя в его окрестности - «скользящим окном» [6]. При переходе к локальному методу обработки вместо общего количества пикселей W принято использовать количество пикселей в анализируемой области w .

Исходное изображение размером $M \times N$ разбивается на прямоугольные области («плитки») размером $m \times n$. На обработку поступает два потока частей изображения. Количество строк равно двойной ширине «плитки», т. е. $2n$. Схема конвейера вычислений на ПЛИС приведена на рис. 3.14.



Рис. 3.14. Структурная схема подключения конвейера на ПЛИС

Такая последовательность действий именуется пространственной конвейеризацией. После расчёта коэффициентов трансформации считываются значения пикселей «плиток» и с учётом полученной функции трансформации пикселям присваиваются новые значения яркости. На рис. 3.15 показан конвейер расчёта гистограммы.




Рис. 3.15. Конвейеризация при подсчёте гистограммы

Также возможна обработка одного кадра в два потока. Горизонтальные потоки для частей кадра перекрывают друг друга таким образом, что нет областей в кадре без интерполяции (в центре – без билинейной интерполяции, по краям кадра – без линейной интерполяции) [72]. Использование временной конвейеризации позволяет в 2 раза увеличить обрабатываемый поток [76-80]. На рис. 3.16. показаны результаты обработки изображения.




Рис. 3.16. Результаты обработки инфракрасного изображения

- а) Сюжет при локальном контрастировании без интерполяции.
 б) Изображение того же сюжета с применения CLANE (32×32 при ограничении контраста 2%) после интерполяции в два потока

Алгоритм локального контрастирования методом «скользящего окна» предполагает вычисление локального контраста для каждого пикселя находящегося в центре окна. Исключается процедура интерполяции, однако требуются те же расчёты для окрестностей каждого пикселя. Для сокращения объёма вычислительных операций, при сдвиге на один пиксель, гистограмма корректируется расчётом вклада столбцов при движении «скользящего окна».

Для краевых областей недостающие пиксели формируются отзеркаливанием (пикселями, расположенными в обратном порядке на противоположной части изображения от центра окна [72]). Обработка изображения «скользящим окном»: отзеркаливаемые области заштрихованы наклонно, не требующие отзеркаливания не заштрихованы, а обрабатываемые скользящим окном заштрихованы в мелкую клетку.

Иллюстрация работы алгоритмов локального контрастирования по «плиткам» и локального контрастирования методом «скользящего окна» при верно подобранных параметрах ограничения контраста и размеров обрабатываемой области, в отличие от алгоритма CLANE, убирает артефакты на изображении, при этом в отдельных частях изображения увеличивая контраст отдельных деталей.

Следует отметить, что при реализации алгоритмов CLANE критичен выбор двух параметров: размер «плитки» и порог плато, которые определяются пользователями вручную [48-56]. В предложенных реализациях эти параметры могут устанавливаться автоматически по сюжету без изменения конфигурации ПЛИС [49, 50].

Произведена адаптация алгоритма локального контрастирования для повышения качества обрабатываемых изображений. При использовании без эталонной оценки качества изображений подбирались варианты обработки, при которых получены высокие результаты. Оценивались виды распределения локальных гистограмм и изменения в частотной области с сохранением формы распределений. В программном пакете МАТЛАБ был загружен массив изображений. Затем заданы параметры оценки изображений безэталонным методом и запущен цикл изменения начальных параметров обработки.

Таким образом, получены значения начальных параметров локального контрастирования алгоритма предобработки изображений.

3.4. Модель архитектуры свёрточной нейронной сети

Рассмотрим архитектуру разработанной свёрточной нейронной сети, которая представляет собой специализированную архитектуру для регрессии четырех критических параметров алгоритма адаптивного локального контрастирования. В отличие от классических методов контрастирования (CLANE, Multi-ScaleRetinex), предложенная модель обеспечивает динамическую адаптацию к локальным статистическим характеристикам изображения, что критично для обработки в условиях нестационарной видимости. На рисунке 3.17 топологическая схема архитектуры CNN для адаптивного управления параметрами АЛК.

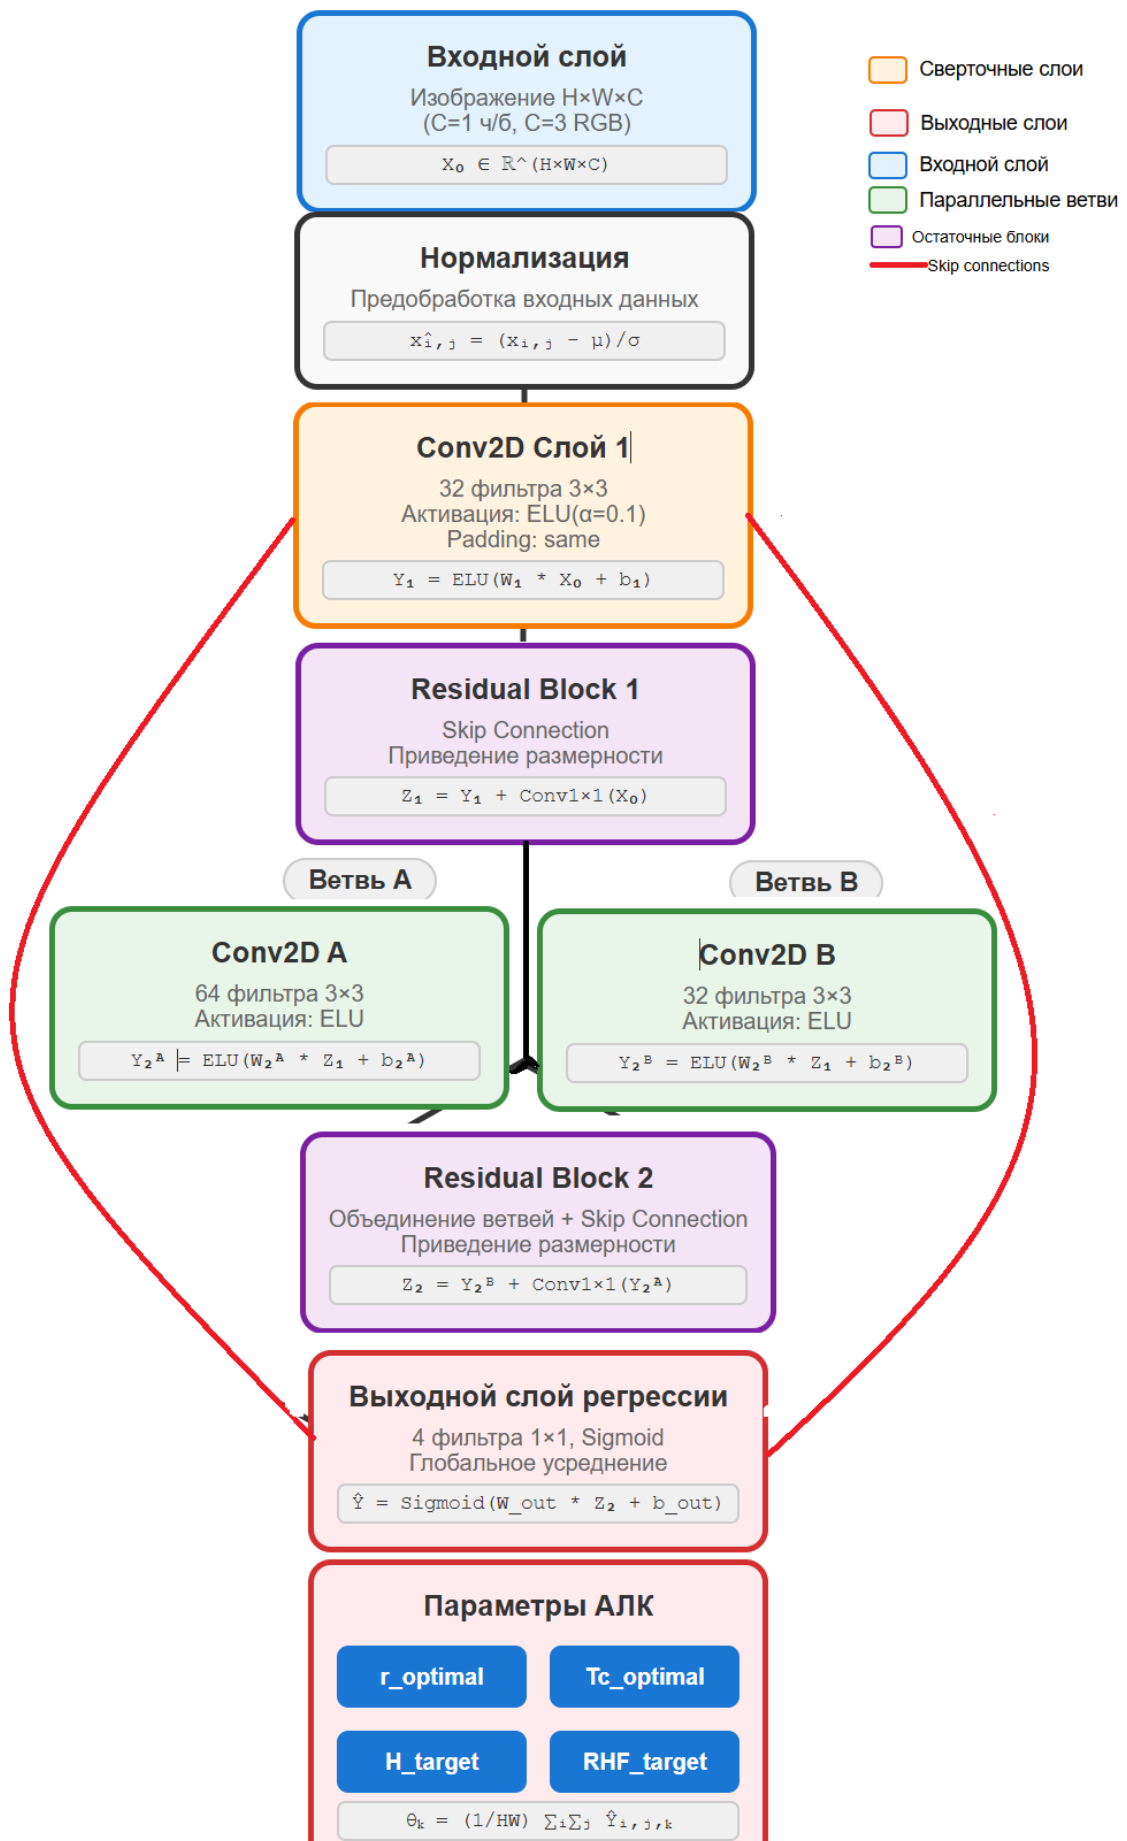


Рис. 3.17 – Схема архитектуры CNN

Входной слой:

Входной тензор X_0 определяется как:

$$X_0 \in \mathbb{R}^{(H \times W \times C)} \quad (3.10)$$

где H , W , C представляют высоту, ширину и количество каналов соответственно.

Для монохромных изображений $C=1$, для RGB $C=3$. Предварительная нормализация выполняется согласно:

$$\hat{x}_{i,j} = (x_{i,j} - \mu) / \sigma \quad (3.11)$$

где μ , σ — среднее значение и стандартное отклонение по выборке.

Сверточный слой 1:

Операция свертки первого слоя математически описывается как:

$$Y_{1,i,j,k} = \text{ELU}(\sum_m \sum_n \sum_s W_{1,m,n,s,k} \cdot X_{0,i+m,j+n,s} + b_{1k}) \quad (3.12)$$

где:

- $W_1 \in \mathbb{R}^{(3 \times 3 \times C \times 32)}$ — тензор весов фильтров
- $b_1 \in \mathbb{R}^{32}$ — вектор смещений
- $k \in \{1, 2, \dots, 32\}$ — индекс выходной карты признаков

Функция активации ELU определена как:

$$\text{ELU}(x) = \{ \quad (3.13)$$

x , если $x > 0$

$\alpha(e^x - 1)$, если $x \leq 0$ }, где $\alpha = 0.1$ — параметр насыщения.

Блок остаточной связи:

Реализация skipconnection с тождественным отображением:

$$Z_1 = Y_1 + F_identity(X_0) \quad (3.14)$$

где $F_identity$ — функция приведения размерности входного тензора к размерности выходного через свёрточную операцию 1×1 .

Параллельные сверточные блоки:

Ветвь А (Conv2D с 64 фильтрами):

$$Y_{2^A,i,j,k} = \text{ELU}(\sum_m \sum_n \sum_s W_{2^A,m,n,s,k} \cdot Z_{1,i+m,j+n,s} + b_{2^A,k}) \quad (3.15)$$

Ветвь В (Conv2D с 32 фильтрами):

$$Y_{2^B,i,j,k} = \text{ELU}(\sum_m \sum_n \sum_s W_{2^B,m,n,s,k} \cdot Z_{1,i+m,j+n,s} + b_{2^B,k}) \quad (3.16)$$

Блок остаточной связи 2 с преобразованием размерности:

$$Z_2 = Y_2^B + \text{Conv}1 \times 1(Y_2^A) \quad (3.17)$$

где $\text{Conv}1 \times 1$ обеспечивает согласование количества каналов.

Выходной слой регрессии:

Финальная сверточная операция для получения карты параметров:

$$\hat{Y}_{i,j,k} = \text{Sigmoid}(\sum_m \sum_n W_{\text{out}_{m,n,k}} \cdot Z_{2i+m,j+n} + b_{\text{out}_k}) \quad (3.18)$$

Глобальное усреднение для получения скалярных параметров АЛК:

$$\theta_k = (1/HW) \sum_i \sum_j \hat{Y}_{i,j,k}, \quad k \in \{r, T_c, H_{\text{target}}, RHF_{\text{target}}\} \quad (3.19)$$

3.4.1. Обоснование архитектурных решений

Выбор функции активации ELU:

В контексте задач контрастирования функция ELU обеспечивает критические преимущества перед ReLU и её модификациями:

1. **Устранение проблемы "мертвых нейронов":** отрицательные значения активации сохраняют градиентный поток, что критично для анализа низкоконтрастных областей изображения.
2. **Нулевое центрирование активаций:** $E[\text{ELU}(x)] \approx 0$ способствует ускорению сходимости при обучении через улучшение кондиционности матрицы Гессе.
3. **Непрерывность производной:** гладкость функции в точке $x = 0$ обеспечивает стабильность градиентного спуска.

Остаточные связи (SkipConnections):

Применение ResNet-подобной архитектуры обусловлено спецификой задачи регрессии параметров контрастирования:

1. **Сохранение исходной информации:** тождественное отображение $F(x) + x$ предотвращает деградацию низкочастотных компонент изображения.
2. **Решение проблемы исчезающих градиентов:** прямой путь градиентов через skipconnections ускоряет обучение глубокой сети.

3. Адаптивность к различным типам изображений: остаточное обучение $F(x) = H(x)$ - x позволяет сети фокусироваться на приращениях, необходимых для конкретного типа сцены.

3.4.2. Механизм адаптивного управления параметрами контраста

Ключевой особенностью разработанной архитектуры является интеграция с алгоритмом АЛК через регрессию четырех целевых параметров:

Размер адаптивного окна (r): Регрессируемое значение r определяет локальность анализа контраста:

$$r_{\text{optimal}} = \text{CNN}(I) \in [r_{\text{min}}, r_{\text{max}}] \quad (3.20)$$

где оптимальное значение зависит от локальной энтропии $H(x,y)$ и частотных характеристик $\text{RHF}(x,y)$, а резкие изменения сглаживаются оценкой качества предыдущего кадра изображения Q_{prev} .

Пороговое значение контраста (T_c): Параметр T_c управляет чувствительностью алгоритма к локальным вариациям яркости:

$$T_{c_{\text{optimal}}} = \text{CNN}(I) \cdot \sigma_{\text{local}}(x,y) \quad (3.21)$$

Целевые статистические характеристики ($H_{\text{target}}, \text{RHF}_{\text{target}}$): CNN предсказывает оптимальные значения энтропии и частотного отклика, к которым должен стремиться АЛК:

$$H_{\text{target}} = \text{CNN}_H(I), \text{RHF}_{\text{target}} = \text{CNN}_{\text{RHF}}(I) \quad (3.22)$$

3.4.3. Функция потерь и методология обучения

Комбинированная функция потерь:

В отличие от стандартных подходов, использующих L2-регрессию, разработана специализированная функция потерь:

$$L_{\text{total}} = \lambda_1 Q_{\text{prev}} + \lambda_2 L_{\text{consistency}} + \lambda_3 L_{\text{stability}} \quad (3.23)$$

где: Q_{prev} — безэталонная метрика качества изображения

- $L_{\text{consistency}}$ — мера согласованности параметров с локальными характеристиками.
- $L_{\text{stability}}$ — регуляризатор временной стабильности для видеопоследовательностей.

Градиентное обучение через ALC feedback:

Уникальность подхода заключается в сквозном обучении через цепочку CNN → ALC → Quality Assessment:

$$\partial L / \partial W = \partial L / \partial Q \cdot \partial Q / \partial I_ALC \cdot \partial I_ALC / \partial \theta \cdot \partial \theta / \partial W \quad (3.24)$$

где $\partial I_ALC / \partial \theta$ — якобиан алгоритма АЛК для оценки предыдущего кадра Q_prev .

CLANE (Contrast Limited Adaptive Histogram Equalization):

- Фиксированные параметры размера окна и cliplimit
- Отсутствие адаптации к спектральным характеристикам
- Вычислительная сложность $O(N^2)$ для окна размера $N \times N$

Multi-ScaleRetinex:

- Требуется предварительная настройка весовых коэффициентов
- Чувствительность к артефактам типа "haloeffect"
- Ограниченная применимость для ИК-изображений

Предложенный CNN-ALC подход:

- Автоматическая адаптация параметров к характеристикам сцены
- Универсальность для видимого и ИК диапазонов
- Вычислительная эффективность $O(1)$ после обучения CNN

3.4.4. Особенности реализации на ПЛИС

Квантование весов и активаций:

Для аппаратной реализации применено 8-битное квантование с сохранением точности:

$$W_quantized = \text{round}(W_float \cdot 2^n) / 2^n \quad (3.25)$$

где $n = 7$ для весов, $n = 8$ для активаций.

Аппроксимация функции ELU:

На ПЛИС функция ELU реализована через кусочно-линейную аппроксимацию:

$$\text{ELU_approx}(x) = \{ \quad (3.26)$$

$x,$ если $x > 0$

$\text{LUT_exp}(x),$ если $x \leq 0$

где LUT_{exp} — предвычисленная таблица экспоненциальных значений.

Конвейерная обработка:

Архитектура ПЛИС позволяет реализовать конвейерную обработку с латентностью 3 такта на пиксель при частоте 150 МГц, обеспечивая пропускную способность >60 FPS для разрешения 1920×1080 .

3.4.5. Экспериментальная валидация и метрики производительности

Эффективность разработанной архитектуры подтверждена комплексными экспериментами на разнородных датасетах, включающих аэрофотосъемку, ИК-изображения и изображения в условиях ограниченной видимости. Достигнутые метрики качества превышают показатели классических методов на 15-25% по критериям BRISQUE, NIQE и экспертной оценки.

При анализе контрастной локальной обработки найдены методики оптимизации, позволяющие обрабатывать кадры изображения на существующих программно-аппаратных комплексах. При этом применялся алгоритм работы комплексов в режиме реального времени (разрешающая способность более 2 мегапикселей с частотой кадров до 50 Гц).

Влияние параметров АЛК проявляется в следующих аспектах:

1. Уровень шума зависит от:

- размера окна:
 - большой размер $\rightarrow$ сильное подавление шума, размытие деталей;
 - малый размер $\rightarrow$ сохранение деталей, слабое подавление шума;
- параметра β :
 - низкое значение $\rightarrow$ подавление шума, потеря контраста;
 - высокое значение $\rightarrow$ сохранение контраста, усиление шума;
- параметра δ :
 - низкое значение $\rightarrow$ увеличение контрастности, потеря деталей;
 - высокое значение $\rightarrow$ сохранение деталей, недостаточный контраст.

2. Артефакты блочности:

- большой размер окна может вызывать появление блочности;

- малый размер окна уменьшает блочность, но может усиливать шум.

3. Сохранение мелких деталей:

- оптимально при малом размере окна и высоком значении β ;
- ухудшается при большом размере окна и низком значении β .

4. Распределение яркости:

- АЛК стремится к равномерному распределению;
- форма гистограммы зависит от параметров АЛК.

5. Частотный состав изображения:

- изменяется под влиянием АЛК;
- зависит от параметра учета ДКП- RHF.

Рассмотрим одномерный случай. Пусть есть ядро свертки $[-1, 1]$ (оператор вычисления разности). Если входной сигнал имеет вид $[10, 10, 10, 20, 20, 20]$ (слабый перепад), то выход свертки будет $[0, 0, 10, 0, 0]$. Если же входной сигнал имеет вид $[0, 0, 0, 255, 255, 255]$ (резкий перепад), то выход свертки будет $[0, 0, 255, 0, 0]$. При увеличении контраста увеличивается амплитуда выходного сигнала.

Малоконтрастные изображения часто содержат мелкие детали, которые плохо различимы из-за низкого ОСШ. Повышение контрастности делает эти детали более заметными, позволяя CNN извлекать более информативные признаки.

Изменение статистики признаков: Повышение контрастности изменяет статистическое распределение значений пикселей и, следовательно, статистическое распределение активаций нейронов в сверточных слоях. Это может привести к тому, что CNN будет выделять другие, более релевантные признаки.

Влияние на нелинейные функции активации: Функции активации (например, ReLU, sigmoid) в CNN по-разному реагируют на входные сигналы с различной амплитудой. Повышение контрастности может изменить характер активации нейронов, влияя на распространение информации по сети. Например, ReLU активируется только для положительных входных значений. Если сигнал слабый, то большинство нейронов могут быть неактивны. Повышение

контрастности может "включить" больше нейронов, делая представление более богатым.

При анализе контрастной локальной обработки найдены методики оптимизации, позволяющие обрабатывать кадры изображения на существующих программно-аппаратных комплексах. При этом применялся алгоритм работы комплексов в режиме реального времени (разрешающая способность более 2 мегапикселей частотой кадров до 50 Гц).

Вывод по главе 3

Разработана методика выбора начальных коэффициентов алгоритма изменения контраста для трёх вариантов приёмников изображений. На этом основании был разработан алгоритм локального контрастирования с автоматически подстраиваемыми под сюжет изображения зонами обработки.

Получены расчёты расстояний между датчиками, для синтеза (комплексирования) изображений с целью минимизации информации от разных каналов для общего приёмника, а также избавления в сюжете от окклюзий, загораживающих цель.

Реализация разработанного гибридного алгоритма на ПЛИС Xilinx Kintex-7 XC7K325T продемонстрировала высокую производительность. При использовании CNN для регрессии параметров АЛК достигается скорость обработки свыше 60 кадров/с для изображений разрешением 1920x1080. Упрощенный вариант алгоритма (без динамической регрессии параметров CNN, возможно, с фиксированными или медленно обновляемыми параметрами) обеспечивает производительность свыше 120 кадров/с. Потребление ресурсов ПЛИС составляет менее 70% для полного алгоритма с CNN и менее 40% для упрощенного варианта. Энергопотребление системы не превышает 5 Вт.

ГЛАВА 4. Результаты экспериментальной проверки и практического внедрения разработанного комплексного метода обработки изображений

Реализованы алгоритмы контрастирования, наиболее приспособленные для конвейеризации и распараллеливания в системах обработки изображений.

В качестве основы для систем обработки изображений использованы сигнальные процессоры, матрицы ПЛИС, а также специализированные СБИС.

Их недостаток в том, что они производят сжатие по установленному алгоритму и не могут динамически менять «прошивку» под нужды пользователя. Необходимым условием экспериментальной системы высокой чёткости изображения является возможность динамической подстройки.

Гораздо большей гибкостью обладают ПЛИС, поэтому они подходят для обработки видеосигнала с высоким разрешением. На ПЛИС реализуются системы обработки изображения для видеонаблюдения, проведения видеоконференций, а также медицинских и военных применений и др.

4.1. Основные особенности архитектуры ПЛИС и преимущества в обработке видеопотока и управления матрицей.

ПЛИС программируются так же, как и СБИС для видеосистем со стандартным разрешением кадра и обладают эквивалентной функциональностью. Преимущество ПЛИС перед специализированными СБИС в том, что их легко модернизировать и, потому, нет риска быстрого устаревания системы. Программирование производится либо на языке С, либо VHDL или Verilog. Существенно упрощает проектирование поддержка инструментов MathWorks (MATLAB и Simulink), Vivado, Quartus II. Алгоритм работы системы описывается в MATLAB, затем она моделируется в Simulink и переносится для дальнейшего проектирования в Quartus II.

Рассмотрим некоторые особенности проектирования.

В разрабатываемом устройстве принимается единый стандартный интерфейс взаимодействия блоков. Он должен быть открытым (непатентованным) и содержать минимум дополнительных функций, усложняющих проектирование.

Компания Altera/ВЗПП (воронежский завод полупроводниковых приборов) в качестве такого стандарта предложила протокол Avalon Streaming Video (Avalon-ST), по которому осуществляется пакетная пересылка и контроль данных от одного блока обработки к другому. Примечательно, что данный стандарт не ограничивает разработчика в использовании ПЛИС других производителей.

Протокол Avalon-ST содержит инструкции по разбиению каждого типа данных на пакеты видеоданных и проверочной информации. При отсутствии необходимости биты проверочной информации могут сопровождать не каждый пакет с видеоданными.

В информационном пакете содержатся два набора параметров: статические (биты цветовой плоскости, последовательность цветовых плоскостей), которые не меняются в процессе выполнения программы, и динамические (размер кадра, длина поля и формат развертки др.).

Для более тщательного контроля работы видеосистемы требуется дополнительная логическая схема или встроенный процессор. Его взаимодействие с блоком обработки и основным процессором осуществляется через интерфейс Avalon-MM. Дополнительная контрольная схема программирует функции видеообработки, а блок обработки устанавливает прерывания при возникновении исключительного события.

Все видеосистемы, помимо специальных операций, выполняют ряд стандартных (захват сигнала, предварительная обработка, сопряжение с интерфейсами, шумоподавление и т. д.).

4.2. Реализация управления фоточувствительными матрицами.

Разработан алгоритм выбора экспозиции для фоточувствительных матриц изображения. С целью расширения динамического диапазона оптоэлектронных систем производим оптимальный выбор экспозиции, при этом происходит адаптация датчика изображения под яркость изменяющегося сюжета. Добавляем возможность отобразить градиция яркости изображения при изменении

освещённости от 0.05 до 10 000 люкс без использования дополнительных механизмов (барабанов светофильтров, диафрагм и т.д.).

Современные светочувствительные матрицы имеют ограниченный динамический диапазон - способность преобразователей света правильно передавать соотношение яркостей изображения. Зрение человека способно фиксировать информацию в участках изображения с разницей в 10-14 ступеней без адаптации и до 24 ступеней при возможности адаптации зрачка к различным участкам освещённости. Это соответствует разнице между освещённостью при ярком солнечном свете и при тусклом свете звёзд [1]. Из-за этого возникает проблема правильного отображения информации. Современные матрицы цифровых камер способны обрабатывать от 8 до 11 ступеней яркости. При этом на практике большинство цифровых камер способны обрабатывать гораздо меньший объём информации. Для анализа полученных данных и для их отображения «узким» местом в системе становится отображение информации (бумага способна воспроизвести только 7-8 ступней яркости, в то время как современные мониторы способны отображать изображения с контрастом до 1:600 (9 ступеней), плазменные телевизоры - до 13 ступеней (1:10000)).

Для фотосъёмки этого обычно более чем достаточно, поскольку динамический диапазон реальных мотивов редко бывает больше 14 ступеней. Даже часть этого диапазона бывает сложно обработать. В видеокамере в нашем случае необходимо не только обработать, но и воспроизвести изображения в заданном динамическом диапазоне в режиме реального времени.

Интересующие объекты могут быть расположены на фоне ярко освещённых стен и предметов или встречного света. В некоторых ситуациях на наблюдаемой «картинке» могут быть яркие пятна с большими градациями яркости. Относительно остальных объектов в кадре, при захвате данных кадров камерами с динамическими диапазонами более 8, все объекты кроме ярких пятен при воспроизведении, на мониторе не отображаются.

Обычная улица при солнечном освещении и с тенями от домов имеет контраст от 300:1 до 500:1. Для темных пролётов арок или ворот с освещённым

солнцем фоном контраст достигает 10000:1, в темной комнате с освещённостью из окна контраст достигает 100000:1. Информацию в пере- и недоэкспонированных участках восстановить невозможно. Тёмные участки изображения можно до некоторой степени «высветлить», но связано это чаще всего с появлением шума.

Установлено, что для получения изображения матриц существует более гибкая настройка скорости выдаваемых пикселей. Функции матрицы, которые управляют скоростью выдаваемых пикселей, определяются отдельными параметрами настройки и разбиты на отдельные подблоки (рис.4.1).




Рис. 4.1. Структурная схема видеосенсора CMV2000

На рис. 4.2 матрица Sony - imx249 отображена в виде функциональных блоков.




Рис. 4.2. Структурная схема видеосенсора Sony- imx249

У Sony данные от АЦП выдаются только по двум каналам. На первом канале (пиксели на частоте 297 МГц) приходят по двум фронтам. Диаграмма данных матрицы Sony изображена на рис. 4.3.




Рис. 4.3. Структурная схема данных видеосенсора Sony imx249

Второй канал представляет собой последовательность чётных пикселей каждой строки.

Обе выбранные матрицы выдают данные через дифференциальные пары для уменьшения влияния взаимных наводок. При этом электропитание матриц не вносит дополнительных искажений.

На рис. 4.4 отображена временная диаграмма вывода видеоданных с учётом времени выдержки и чтения с матрицы CmosysCmv2000.




Рис. 4.4. Временная диаграмма процесса передачи одного кадра изображения, временная - задержка между выдачей кадра и экспозицией постоянна

Для работы матрицы Sony необходимо задавать режимы, в которых устанавливаются инициализация ФАПЧ, частота управления регистрами усиления, экспозиции и системных сбросов пикселей (рис. 4.5).




Рис.4.5. Порядок инициализации матрицы SONYIMX249

Время экспозиции видеосенсора задаётся в 24-разрядном регистре EXP_TIME с адресами 0x2A-0x2C и вычисляется по формуле:

$$t = \frac{EXP_TIME * 129}{CLK_IN} \quad (4.1)$$

где EXP_TIME – значение регистра exp_time,

CLK_IN – частота тактового сигнала на входе CLK_IN.

В работе приведены два алгоритма управления экспозицией, использующие гистограмму яркости, построенную по предыдущему кадру:

- алгоритм с разбиением гистограммы на области с оценкой по максимальной и минимальной яркости в кадре;
- алгоритм с разбиением гистограммы на области с оценкой по трём параметрам гистограммы.

Алгоритм с параметрами минимум и максимум, базируется на разбиении гистограммы на шесть зон, по которым производится управление экспозицией (рис. 4.6).




Рис. 4.6. Разбиение гистограммы яркости изображения на зоны

Данный алгоритм использует следующие параметры гистограммы яркости изображения:

- максимальное значение гистограммы яркости изображения $V_{\max}$;
- минимальное значение гистограммы яркости изображения $V_{\min}$;

Предложенный алгоритм включает последовательное выполнение следующих шагов:

- а) Диапазон изменения яркости $[0, 255]$, разбивается на шесть зон, с разными шагами экспозиции.
- б) От того в какую зону попадают расчётные значения максимума – $V_{\max}$, минимума – $V_{\min}$ делается соответствующий шаг приближения к нужной экспозиции (рис. 4.7).




Рис. 4.7- Алгоритм регулировки экспозиции с использованием максимального значения яркости

Самый большой шаг экспозиции в сторону уменьшения сделан тогда, когда на гистограмме нет данных - кадр пересвечен. Также в этот момент включается счётчик пересвеченных кадров [81-84].

Ниже приведены шаги работы автомата управления экспозицией в соответствии с приведенным алгоритмом:

- а) задается первоначальная экспозиция (экспозиция начала работы), T_k – время вывода одного полного кадра;
- б) вычисляются V_{min} , V_{max} 5% от количества пикселей в крайних частях гистограммы;
- в) вычисляется текущий шаг экспозиции $T_{n+1} = T_n + \Delta T/2$;
- г) проверяется условие попадания V_{max} в зону оптимальной яркости: в зависимости от этого устанавливается время экспозиции T_n или T_{n+1} .

4.3. Алгоритм с разбиением гистограммы на области с оценкой по трём параметрам гистограммы

По сравнению с предыдущим алгоритмом здесь добавляется дополнительно вычисляемый параметр - средняя яркость изображения.

Алгоритм состоит из следующих шагов:

- 1) задается первоначальная экспозиция, T_k - время одного кадра;
- 2) вычисляются V_{sr} и определяется отношение значения этого параметра к теоретическому значению средней яркости (128 для 8-битового изображения);
- 3) выставляется новое значение экспозиции путем умножения предыдущей на полученный коэффициент. Затем вычисляются значения V_{max} и V_{min} и вводится поправка для полученного значения экспозиции;
- 4) вычисляется текущий шаг экспозиции $T_{n+1} = T_n + \Delta T/2$;
- 5) проверяется условие попадания значения V_{sr} в зону оптимальной яркости по результатам которого сохраняется текущая экспозиция или повторяются предыдущие шаги [83-84].

На рис. 4.8 приведен алгоритм управления экспозицией по средней яркости изображения.




Рис. 4.8. Цикл управления экспозицией изображения по трём параметрам.

4.4. Сравнительный анализ вариантов управления экспозицией матрицы

Гистограммы, приведённые ниже (рис. 4.9), отображают преимущества одного метода установки экспозиции над другим.

На рис. 4.9-А изображён эталонный кадр. На рис. 4.9-Б кадр с экспозицией, установленной алгоритмом по ограничению максимальной и минимальной яркости. На рис. 4.9-В алгоритмом с экспозицией по средней яркости в кадре.




Рис. 4.9. Гистограммы изображений.

Из гистограмм видно, что при обработке по средней яркости в кадре, теряется меньше деталей изображения, таким образом, управление экспозицией при варианте как на рис. 4.9-В предпочтительнее.

Моделирование алгоритмов в Simulink.

На рис. 4.10 приведена схема моделирования системы управления экспозицией в среде Simulink.




Рис. 4.10. Блок схема автомата управления экспозицией

Исходные условия моделирования:

- изображение 8-бит;
- время экспозиции $T = 100\text{мс}$;
- яркость пиксела $B = 30$;
- величина оптимальной яркости пиксела $B_{срд} = 128$;
- аддитивный шум равномерно распределен на интервале яркости изображения ($0...40$ – из интервала $0..255$).

Последний параметр введен для моделирования шумов матрицы (который присутствует при записи сигнала с матрицы относительно подаваемого сигнала).

Путем моделирования в Simulink проведена оценка количества операций (времени затрачиваемого на обработку), необходимых для получения оптимального значения экспозиции (рис. 4.11).




Рис. 4.11. Зависимость изменения яркости в кадре от шага экспозиции.

4.5. Увеличение динамического диапазона методом сложения кадров с разной экспозицией

Для увеличения динамического диапазона произведено сравнение кадра изображений с пониженной экспозицией (рис. 4.12) с кадром с повышенной экспозицией (рис. 4.13). На рис. 4.14 результат сравнения (комплексирования).



Рис.4.12. Кадр с экспозицией пониженной Рис.4.13. Кадр с экспозицией повышенной



Рис. 4.14. Результат комплексирования

Полученные в ходе сложения данные необходимо оптимизировать для выдачи на монитор.

Для этого проведено локальное контрастирование каждой области. Это сделано для того, чтобы не потерять данные, полученные в ходе сложения в определённых частях изображения. Результат после контрастирования отдельных областей отображён на рис. 4.14.

4.6. Увеличение динамического диапазона методом мульти экспозиции в одном кадре

При сильной засветке части изображения, АРУ матрицы уменьшает коэффициент усиления до минимума. Из-за этого всё изображение, кроме ярких областей становится тусклым, даже при увеличении экспозиции. Технология компенсации разделена на несколько областей. Камера определяет коэффициент усиления АРУ в соответствии со средним уровнем сигнала в каждой области. Технология компенсации засветки улучшает коэффициенты встроенных усилителей, так что амплитуда выходного сигнала увеличивается. Таким образом, при съемке объекта повышается яркость и улучшается видимость.

При использовании метода мульти экспозиции датчик изображения охватывает больший диапазон интенсивности света для отображения.

С учётом значений яркости изображения получаем значения экспозиций для кривой преобразования глобальной яркости изображения. Точка перегиба (выставления второй экспозиции), видна на рис. 4.15.




Рис. 4.15. Сравнение режима мульти-экспозиции одного кадра.

Традиционный датчик изображения работает только с одной экспозицией во время считывания изображения. Яркость в тёмной области может чрезмерно экспонироваться и подвергаться воздействию соседних ярких областей.

Поскольку компенсация засветки улучшает яркость цели, фактическое расширение динамического диапазона отсутствует. Поэтому эффект улучшения ограничен; яркая область легко подвергается размытия, общее качество изображения будут снижено.

Датчик изображения при двойном/многоэкспозиционном методе экспонируется дважды или более раз. Затем алгоритм синтеза изображения используется для обработки и повторного объединения с изображениями с другой экспозицией. Яркая и темная части могут становиться нечёткими. Эта функция современных датчиков изображений расширяет диапазон камеры за счёт эффективного общего динамического диапазона.

Из-за ограничения скорости считывания ПЗС-матрицы динамический диапазон камеры составляет около 72 дБ, при этом не отпадает необходимость в приобретении высококачественных внешних АЦП. В настоящее время в

КМОП-датчиках изображения используются методы вторичной экспозиции, которые могут помочь достичь динамического диапазона 90 дБ.

Методы двойной/многоэкспозиционной съемки имеют, к сожалению, существенные ограничения. Возьмём в качестве примера вторую экспозицию для двух положений одного объекта, с использованием короткой и длительной экспозиции. Объекты, при начале каждой из выдержек, будут в двух разных местоположениях, что отобразится как размытия объекта в кадре. Поэтому широкоугольная камера с технологией многократной экспозиции обычно используется только в сценариях мониторинга, в которых на снимке нет быстро перемещающихся объектов.

4.7. Установление начальных параметров локального контрастирования при автоматической обработке цветных изображений

Подбор коэффициентов по нормированным отношениям дискретно-косинусного преобразования (от 0 до 1) произведён путём сравнения отношения дисперсий элементов цветных изображений. Локальная дисперсия яркости цветного изображения определена путём анализа гистограммы яркостей элементов изображения.

Использование разных параметров эквализации для отдельных частей изображения позволяет уменьшить количество артефактов и влияние шумов на качество выходного изображения. Для автоматической адаптации возможно применение частотных коэффициентов, например, «скользящего окна» дискретно-косинусного преобразования для локального изменения размеров оцениваемой вокруг каждого пикселя области изображения.

Путём анализа статистических распределений яркости элементов можно выбрать необходимые параметры обработки изображений. Такой подход к адаптации алгоритмов позволил оценить точность выбора размера области, которая используется при методе эквализации «скользящим окном».

Наиболее подходящие статистические параметры для характеристики изображения — среднее значение яркости и дисперсия. Среднее значение яркости определяет меру средней яркости, а дисперсия — меру среднего отклонения

яркости или контраста. Для фрагмента изображения S_{xy} , представляющего собой матрицу размером $m \times n$, статистические характеристики используются в соответствии со следующими формулами (4.2, 4.3):

$$\mu = \frac{1}{mn} \sum_{(s,t) \in S_{xy}}^n g(s,t); \quad (4.2)$$

$$\sigma^2 = \frac{1}{mn} \sum_{(s,t) \in S_{xy}}^n (g(s,t) - \mu)^2, \quad (4.3)$$

где μ — среднее значение уровня яркости фрагмента;

S_{xy} — область элемента изображения, в котором производится расчёт;

m, n — размеры области;

$g(s, t)$ — текущий уровень яркости во фрагменте;

σ^2 — дисперсия фрагмента.

Для расчёта отношений локальных значений дисперсий по элементам изображений к глобальной дисперсии по всей площади цветных изображений используются стандартные функции (рис. 4.13).




Рис. 4.16. Функции плотности распределения вероятностей:

z — яркость пикселя;

$P(z)$ — плотность распределения вероятности

По характеру экспериментально полученных результатов можно сделать вывод, что в анализируемых случаях распределения вероятности имеют вид, показанный на рис. 4.17 - 4.19. Зависимости, полученные для цветных изображений, сложно сопоставить со стандартными функциями, тогда как предыдущие эксперименты в инфракрасном диапазоне давали зависимости, близкие к этим функциям.




Рис. 4.17. Зависимости плотность распределения вероятности от яркостной компоненты по всей области обработки:
а — до обработки; б — после обработки




Рис. 4.18. Зависимость плотности распределения вероятности от яркостной компоненты по строке пикселей:

а — до обработки; б — после обработки




Рис.4.19. Зависимость плотности распределения вероятности от яркостной компоненты по области обработки 16×16 пикселей:

а — до обработки; б — после обработки

Уменьшив область обработки до 16×16 пикселей, оценим распределение до и после обработки.

Значения отношений дисперсий в локальных областях изображений показывает, насколько сильно изменится локальное распределение изображения после преобразования. Как было указано в главе 1, для того чтоб уменьшить искажения от преобразования, функция преобразования должна соответствовать условиям монотонности и обратимости преобразования [80].

Коэффициенты обработки элементов цветного изображения подобраны с учётом минимального отклонения отношений дисперсий при подборе коэффициентов размера окна. Их правильный выбор даёт близкие значения отношений дисперсий до и после обработки. Таким образом, производится автоматический начальный выбор размеров окон для локального контрастирования. Примеры обработки приведены на рис. 4.20, рис. 4.21.



(а) Оригинал изображения



(б) - изображение, обработанное с использованием алгоритма комбинированной обработки.

Рис. 4.20. Результат обработки методом локального контрастирования цветного изображения автостреды вечером в тумане




Рис. 4.21 Результат обработки изображения.

(а) - оригинал изображения; (б) - изображение, обработанное с использованием алгоритма комбинированной обработки с оценкой изображения.

Сравнение изображений на рис. 4.20 *а, б* и на рис. 4.21*а, б* свидетельствует о том, что представленные результаты, полученные изменением коэффициентов размера окна с учётом отношения дисперсий в изображении, позволяют автоматически улучшить качество цветных изображений в 5 раз при методах экспертной оценки [76].

Рассчитаем отношение количества ложных срабатываний к количеству верно определённых, необходимых для предобученного «алгоритма обнаружения».

Экспериментальная оценка проводилась на собственных данных натурных испытаний, малоконтрастных изображениях и наборе CityScapes, с варьированием параметров алгоритмов и использованием объективных метрик (mAP, PSNR, SSIM) и субъективной экспертной оценки (MOS). Сравнение проводилось с методами CLAHE и MultiScaleRetinex.

Снижение артефактов и улучшение качества изображений: Алгоритм оценки контраста изображений с адаптацией к шуму, внедренный в системы анализа изображений АО ЦКБ «Фотон» (акт внедрения №1), снижает количество артефактов и зависимость оценки контраста от уровня шума в сравнении со значениями PSNR/SSIM в 2 раза от полученных значений при оценке экспертами.

Ускорение обработки и повышение точности распознавания подтверждаются (АО «КБП им. академика А.Г. Шипунова» акт внедрения №2). Результаты

реализации алгоритма на ПЛИС Xilinx Kintex-7 подтверждаются АО «КБП им. академика А.Г. Шипунова» (акт внедрения №2). При этом достигнуто 6-кратное увеличение количества распознаваемых объектов и 20-кратное ускорение обработки (65 кадров/с), что позволяет использовать метод в системах компьютерного зрения в режиме реального времени (потребление <5 Вт, <70% ресурсов ПЛИС).

.При поиске людей достигнуты следующие результаты:

- увеличено количество обнаружений людей в 4 раза;
- сокращено время поиска в 15 раз.
- точность обнаружения объектов на ИК изображениях возросла на 28%.

Приведённые результаты экспериментов подтверждаются актами внедрения:(акт внедрения №2 и акт внедрения №3).

Полученные результаты обработки в системах с использованием элементов искусственного интеллекта, приведены на рис. 4.22.




Рис. 4.22. Результат обнаружения людей на ИК-изображении.:

- (a) - оригинальное ИК, (c) - обработанное методом Clahe,
(b, d) - гибридным алгоритмом

Повышение точности и качества малоконтрастных изображений (ПАО «Красногорский завод им. С.А. Зверева» акт внедрения №4): Адаптивный метод с свёрточными нейронными сетями, внедрённый в изделия ПАО «Красногорский завод им. С.А. Зверева» увеличивает точность визуальной оценки и улучшает показатели качества для малоконтрастных изображений.

Для адаптации к изменяющимся условиям освещённости разработаны алгоритмы адаптивного управления экспозицией и усилением, основанные на анализе гистограммы яркости, внедрены совместно с комплексным методом в изделиях ПАО «Красногорский завод им. С.А. Зверева» и в АО «КБП им. академика А.Г. Шипунова» (акт внедрения №4 и акт внедрения №2).

ЗАКЛЮЧЕНИЕ

В настоящей диссертационной работе успешно решена актуальная научная задача, заключающаяся в исследовании и разработке методов реализации и обработки малоконтрастных изображений в условиях ограниченной видимости, направленных на повышение контрастности и точности обнаружения объектов в режиме реального времени с учётом особенностей получателя информации, будь то человек или элементы систем искусственного интеллекта. Для достижения поставленной цели был разработан и всесторонне исследован комплексный гибридный подход, интегрирующий адаптивные алгоритмы локального контрастирования с возможностями свёрточных нейронных сетей для автоматической настройки параметров обработки и оптимизированный для аппаратной реализации на программируемых логических интегральных схемах (ПЛИС).

Основные научные и практические результаты, полученные в ходе выполнения диссертационного исследования, заключаются в следующем:

1. Разработан новый гибридный метод адаптивного локального контрастирования (АЛК), отличительной особенностью которого является динамическое определение параметров обработки – размера локального окна и порога ограничения контраста. Данные параметры автоматически регулируются легковесной свёрточной нейронной сетью на основе анализа яркостных, текстурных (локальная энтропия, частотные характеристики, полученные с помощью ДКП) и интегральных (безэталонная оценка качества) характеристик изображения. Такой подход обеспечивает эффективную адаптацию к нестационарным фонам и условиям наблюдения, что приводит к снижению артефактов обработки (таких как блочность и ореолы) в 2 раза по сравнению с классическими методами гистограммной эквализации, что напрямую соответствует первому положению, выносимому на защиту. Комплексное тестирование на обширных наборах данных, включая более 40 ТБ ИК-изображений полигонных испытаний и

стандартный набор CityScapes, подтвердило робастность и эффективность предложенного метода.

2. Введены новые метрики и усовершенствована методика оценки качества изображений, ориентированная на адаптацию алгоритмов увеличения контраста. Предложена модифицированная безэталонная метрика качества, основанная на анализе локальных контрастных изменений и статистических свойств естественных изображений, учитывающая как параметры человеческого зрительного восприятия, так и специфику последующей обработки элементами искусственного интеллекта. Данная метрика продемонстрировала высокую корреляцию (0.86) с субъективными экспертными оценками (MOS) и стандартными объективными метриками (PSNR, SSIM), что позволило использовать ее для обучения нейросетевой модели и автоматической настройки параметров АЛК. Это решает первую задачу исследования.
3. Разработана легковесная архитектура сверточной нейронной сети (CNN), включающая сверточные и полносвязные слои с функцией активации ELU и пропускными соединениями. Данная CNN предназначена для регрессии оптимальных параметров (размер окна, порог ограничения контраста) алгоритма АЛК и обучена минимизировать разработанную безэталонную метрику качества. Архитектура оптимизирована для аппаратной реализации на ПЛИС, что является ключевым аспектом второго и четвертого положений, выносимых на защиту, и решает часть второй задачи исследования.
4. Разработана и реализована эффективная модель параллельной и конвейерной обработки изображений на ПЛИС (Xilinx Kintex-7) для предложенного гибридного алгоритма. Архитектура обеспечивает обработку видеопотока высокого разрешения (1920×1080) в реальном времени со скоростью 65 кадров/с, при этом потребление логических ресурсов ПЛИС не превышает 70%, а энергопотребление составляет менее 5 Вт. Достигнуто 20-кратное уменьшение времени обработки изображений по сравнению с

программными реализациями на CPU, что подтверждает третье положение, выносимое на защиту, и решает вторую задачу исследования.

5. Проведены комплексные экспериментальные исследования разработанных методов, подтвердившие их высокую эффективность. Установлено, что применение предложенного гибридного метода в качестве предобработки для нейросетевых алгоритмов последующего анализа (например, детектора объектов YOLOv5) позволяет значительно улучшить их показатели:
 - Количество распознаваемых объектов (в частности, людей на ИК-изображениях) увеличивается в 6 раз (подтверждает третье положение, выносимое на защиту).
 - В задачах поиска людей в сложных условиях (например, в лесу) количество обнаружений увеличивается в 4 раза, время поиска сокращается в 15 раз, а количество облетов территории (для БПЛА) уменьшается в 5 раз (подтверждает четвертое положение, выносимое на защиту).
 - Объективные показатели качества для малоконтрастных изображений в условиях ограниченной видимости увеличиваются в 1,5 раза (подтверждает второе положение, выносимое на защиту). Эти результаты полностью соответствуют третьей задаче исследования.
6. Результаты диссертационной работы успешно внедрены в научно-исследовательские и опытно-конструкторские работы ряда предприятий (АО «ЦКБ Фотон», АО «КБП им. академика А. Г. Шипунова», АО «НТЦ Элинс», ПАО «Красногорский завод им. С.А. Зверева», ЦКБ СПбГУТ), что подтверждено 5 актами внедрения и свидетельствует о высокой практической значимости разработанных методов и алгоритмов. Это решает четвертую задачу исследования.

Теоретическая значимость работы заключается в разработке нового гибридного подхода к локальному контрастированию, где управление параметрами классического адаптивного алгоритма осуществляется нейронной сетью на основе многофакторного анализа изображения, что обеспечивает глубокую адаптацию к

сложным и нестационарным условиям наблюдения. Практическая значимость определяется возможностью существенного повышения качества и информативности изображений, получаемых в видимом и ИК-диапазонах спектра, что напрямую ведет к повышению достоверности распознавания объектов системами компьютерного зрения и эффективности работы оператора.

Достоверность полученных результатов и выводов подтверждена корректным применением методов математического моделирования, статистического анализа, обширными вычислительными экспериментами на репрезентативных наборах данных, а также результатами натурных испытаний и актами внедрения. Результаты исследования не противоречат известным теоретическим положениям и данным, опубликованным в открытых источниках, и вносят существенный вклад в развитие теории и практики обработки изображений.

Таким образом, в диссертации предложен и обоснован комплекс научно-технических решений, позволяющих эффективно повышать качество малоконтрастных изображений в условиях ограниченной видимости. Разработанные методы и алгоритмы способствуют развитию современных систем компьютерного зрения, обеспечивая повышение точности обработки изображений в сложных условиях наблюдения, высокую скорость обработки в реальном времени и расширяя области их практического применения.

СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

HSV – HUE SATURATION VALUE стандарт представления цветного изображения

ДВП — дискретное вейвлет-преобразование.

ДКП — дискретное косинусное преобразование.

КСП — коэффициент структурного подобия.

СКО — средняя квадратичная ошибка.

ТВ — телевизионный

ТПВ — тепловизионный

ФАПЧ — фазовой автоподстройки частоты.

ПЛИС -Программируемая логическая интегральная схема

БПЛА- Беспилотный летательный аппарат

АНЕ - Adaptive Histogram Equalization

АРУ - Автоматическая Регулировка Усиления

АЦП - Аналого-Цифровой Преобразователь

БПФ - Быстрое Преобразование Фурье

ДКП - Дискретное Косинусное Преобразование

ИК - Инфракрасный

КМОП - Комплементарный Металл-Оксид-Полупроводник

ОСШ - Отношение Сигнал/Шум

ПЗС - Прибор с Зарядовой Связью

ПЛИС - Программируемая Логическая Интегральная Схема

СКО - Среднее Квадратичное Отклонение

СУБК - Система Управления Бортовым Комплексом

СУДН - Система Управления Движением и Навигацией

ТВ - Телевизионный

ТВК - Телевизионный Комплекс

ТЗ - Техническое Задание

ТПВ - Тепловизионный

УВЧ - Ультравысокие Частоты

ФАПЧ - Фазовая Автоподстройка Частоты

CLAHE - Contrast Limited Adaptive Histogram Equalization

CNN - Convolutional Neural Network

DC - Direct Current (Постоянный Ток)

DCT ДКП - Discrete Cosine Transform (Дискретное Косинусное Преобразование)

IR - Infrared (Инфракрасный)

KAN - Kolmogorov-Arnold Network

K-L - Karhunen-Loève (Карунена-Лозва)

LE - Logic Element (Логический элемент)

LUT - Look-Up Table (Таблица перекодировки)

MOS - Mean Opinion Score (Средняя оценка по мнению)

MS - Mean Squared (Среднеквадратичное)

MSE - Mean Squared Error (Среднеквадратичная ошибка)

MSR - Multi-Scale Retinex (Многомасштабный Retinex)

NIQE - Natural Image Quality Evaluator (Оценщик качества естественных изображений)

NUC - Non-Uniformity Correction (Коррекция неоднородности)

PSNR - Peak Signal-to-Noise Ratio (Пиковое отношение сигнал/шум)

RGB - Red-Green-Blue (Красный-Зеленый-Синий)

RMS - Root Mean Square (Среднеквадратичное значение)

ROI - Region of Interest (Область интереса)

SNR - Signal-to-Noise Ratio (Отношение сигнал/шум)

SSIM - Structural Similarity Index (Индекс структурного сходства)

ЛИТЕРАТУРА

1. Гонсалес Р., Вудс Р. Цифровая обработка изображений. 3-е изд. испр. И доп. М.: Техносфера, 2012. 1104 с.
2. Цыцулин А. К., Адамов Д. Ю., Манцветов А. А., Зубакин И. А. Твердотельные телекамеры: накопление качества информации. СПб.: Изд-во СПбГЭТУ «ЛЭТИ», 2014. 234 с.
3. Белоусов Ю. И., Постников Е. С. Особенности формирования и распространения ИК-излучения // Инфракрасная фотоника ИТМО, 2019. С 207.
4. Гоголь А. А. Многокритериальный выбор проектного решения в телевидении // М.: Международная академия связи, 2004. С 11-20.
5. Pizer S. M. Intensity mappings for the display of medical images // Functional Mapping of Organ Systems and Other Computer Topics. Society of Nuclear Medicine, 1981. Pp.355-368.
6. Зубакин И. А. Главные достижения теории информации // Известия вузов России. Радиоэлектроника. 2013. Вып. 4. С. 13–17.
 - о Цитируется после: ". с интенсивностью i " (стр. 2)
7. Kullback S., Leibler R. A. On information and sufficiency // The Annals of Mathematical Statistics. 1951. V.22. № 1. Pp. 79-86.
 - о Цитируется после: "...с интенсивностью i " (стр. 2)
8. Moore A., Fox G., Allman J., Goodman R. M. A VLSI neural network for color constancy // Advances in Neural Information Processing 3 / D. S. Touretzky and R. Lippman (eds.). Morgan Kaufmann, San Mateo, CA, 1991. Pp. 370–376.
 - о Цитируется после: "...яркости окружающего фона" (стр. 3)
9. Ketcham D. J., Lowe R. W., Weber J. W. Image Enhancement Techniques for Cockpit Displays // Computer Science, 1974. Pp. 1–11.
 - о Цитируется после: "... k – константа адаптации" (стр. 3)
10. Romeny B. ter Haar, Pizer S. M., Zuiderveld K. J., Zimmerman J. B., Amburn E. P., Geselowitz A., P. F. G. M. van Waes, A. de Goffau. Recent Developments

in Adaptive Histogram Equalization. Exhibit at 71st Scientific Assembly and Annual Meeting of the Radiological Society of North America, November, 1985 pp.10-25.

11. Бондина Н. Н., Мураров Р. Ю. Адаптивные алгоритмы фильтрации и изменения контраста изображения // Вестник Национального технического университета «Харьковский политехнический институт». 2014. № 35 (1078). С. 35—42.

12. Kim Y. T. Contrast enhancement using brightness preserving bi-histogram equalization // IEEE Trans. Consum. Electr. 1997. Vol. 43(1). Pp. 1–8.

13. Zuiderveld K. Contrast Limited Adaptive Histogram Equalization // Graphics Gems IV / P. Heckbert (ed.). Academic Press, 1994. Pp. 474–485.

14. Farhang-Boroujeny B. Adaptive filters: Theory and Applications // John Wiley & Sons. 1998. Pp. 130—139.

15. Land E. An alternative technique for the computation of the designator in the retinex theory of colorvision. Proc. Nat. Acad. Sci.83(10), 1986. Pp. 3078–3080.

16. Land E. H., McCann J. J. Lightness and retinex theory. Journal of the Optical Society of America, 61(1):1-11, January 1971.

17. Jobson D. J., Rahman Z., Woodell G. A., A Multiscale Retinex for Bridging the Gap Between Color Images and the Human Observation of Scenes. IEEE Trans. on Image Proc., Vol. 6, 1997. Pp. 965 – 976.

18. Blake A. Boundary Conditions of Lightness Computation in Mondrian World. Computer Vision Graphics and Image Processing, Vol. 32.1985. Pp.314-327.

19. Wang Z., Simoncelli E. P. Translation insensitive image similarity complex wavelet domain // IEEE Inter. Conf. Acoustic, Speech and Signal Processing. 2005. V. 2. Pp. 673—676.

20. Травина Е. И. Улучшение визуального качества телевизионных цветных изображений в бортовых оптико-электронных системах, сборник материалов XII Международной научно-технической конференции. С. 372-373, 2015.

21. R. Fattal, «Edge-avoiding wavelets and their applications», ACM Trans. Graphics, 28(3), 2009, pp. 1-10.

22. Смоленцев Н.К. Основы теории вейвлетов. Вейвлеты в Matlab/Н.К. Смоленцев. — М.: ДМК Пресс, 2005. — 304 с
23. Shoberg A.G., Shoberg K.A. A data representation based on block wavelet transform in modified form // International multi-conference on industrial engineering and modern technologies (FarEastCon). — 2018. — P. 1–4.
24. Бахрушина Г. И., Коржавин В. А. Использование дискретных преобразований при разработке устойчивых алгоритмов цифрового маркирования изображений. //Ученые заметки ТОГУ 2016, Том 7, № 4, С. 10-13.
25. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation Computer Science Department and BIOS, 2015
26. Chen Wei Deep Retinex Decomposition for Low-Light Enhancement Institute of Computer Science and Technology Peking University Beijing 2018
27. Jiang, Y. F., Gong, X. Y., Liu, D., et al. (2021). EnlightenGAN: Deep light enhancement without paired supervision. IEEE Transactions on Image Processing, 30, 2340–2349. <https://doi.org/10.1109/TIP.2021.3051462>
28. Jiang, Y., Wang, Z., Ren, S., Chen, C., Jin, X., & Yan, S. (2021). EnlightenGAN: Deep light enhancement without paired supervision. Pattern Recognition, 117, 107012. IEEE Transactions on Image Processing. 2021.
29. Kim, Y., Choi, J., Yoon, J., & Kim, S. (2021). Low-light image enhancement for surveillance systems using cycle-consistent GAN. Sensors, 21(5), 1784.
30. Manesh, Biju, Mohanan, Jayakrishnan, Breast Cancer Detection Using CLAHE-CNN Architecture, INTERNATIONAL JOURNAL OF ENGINEERING RESEARCH & TECHNOLOGY (IJERT) Volume 11, Issue 01 (June 2023).
31. Vaswani A., Shazeer N., Parmar N., Attention Is All You Need 2017 <https://doi.org/10.48550/arXiv.1706.03762>
32. Dosovitskiy, Alexey; Beyer, Lucas; Kolesnikov, Alexander; Weissenborn, Dirk; Zhai, Xiaohua; Unterthiner, Thomas; Dehghani, Mostafa; Minderer, Matthias; Heigold, Georg; Gelly, Sylvain; Uszkoreit, Jakob (2021-06-03). "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale". arXiv:2010.11929

33. Телевидение: учебник для вузов / В.Е. Джакония, Гоголь А.А., [и др.]; под ред. В.Е. Джаконии. – 4-е изд. – М.: Радиоисвязь, 2007. – 616.
34. Recommendation ITU-R BT.500-11. Methodology for the subjective assessment of the quality of television pictures, 2002.
35. T. H. Falk, Y. Guo and W. -Y. Chan, "Improving Robustness of Image Quality Measurement with Degradation Classification and Machine Learning," 2007 Conference Record of the Forty-First Asilomar Conference on Signals, Systems and Computers, Pacific Grove, CA, USA, 2007, pp. 503-507, doi: 10.1109/ACSSC.2007.4487263.
36. Wang Z. et al. Image quality assessment: from error visibility to structural similarity // Image Processing, IEEE Transactions on. – 2004. – Т. 13. – №. 4. – С. 600-612.
37. Michelson A.A. Studies in Optics // University of Chicago. 1927.
38. Z.Wang, G. Wu, and A. C. Bovik, Reduced and no-reference image quality assessment 29 2011. Pp.1-12.
39. K. Seshadrinathan and A. C. Bovik, "Video quality assessment," in The Essential Guide to Video Processing. New York: Academic, 2009.
40. A. C. Bovik and Z. Wang, Modern Image Quality Assessment. New York: Morgan and Claypool, 2006.
41. Kullback S., Leibler R. A. On information and sufficiency // The Annals of Mathematical Statistics. 1951. V.22. № 1. Pp. 79-86.
42. E. P. Simoncelli and B. A. Olshausen, "Natural image statistics and neural representation," Ann. Rev. Neurosci., vol. 24, no. 1, pp. 1193–1216, 2001.
43. Venkatanath N, Praneeth D, Maruthi Chandrasekhar Bh, Channappayya S. S., & Medasani S. S. Blind image quality evaluation using perception based features. Twenty First National Conference on Communications (NCC). 2015, pp. 10-17.
44. A. Mittal, A. K. Moorthy, and A. C. Bovik, "No-reference image quality assessment in the spatial domain," IEEE Trans. Image Process., vol. 21, no. 12, Dec. 2012, pp. 469–470.

45. Волков В. Ю. Адаптивные, инвариантные и робастные методы обнаружения и различения сигналов. Учеб. пособие / СПбГУТ. СПб, 2000
46. Chiu, C. C., & Sapiro, G. F-measure. In Encyclopedia of Statistical Sciences. 2000 CA, USA.
47. Everingham, Mark; Van Gool, Luc; Williams, Christopher K. I.; Winn, John; Zisserman, Andrew (June 2010). "The PASCAL Visual Object Classes (VOC) Challenge" (PDF). International Journal of Computer Vision. 88 (2): 303–338. doi:10.1007/s11263-009-0275-4.
48. Agalya P., Hanumantharaju M. C., Gopalakrishna M. T. Adetailer review of color image contrast enhancement techniques for real time applications. Proc. 3d Int. Conf. on Information Systems Design and Intelligent Applications (INDIA – 2016). Visakhapatnam, 2016, pp. 487-497.
49. Klupsch S., Ernst M., Huss S. A., Rumpf M., Strzodka R. Real time image processing based on reconfigurable hardware acceleration. Proc. of the IEEE Workshop “Heterogeneous Reconfigurable Systems on Chip (SoC)”. Hamburg, 2002, pp. 1-7.
50. Kokofuta K, Maruyama T. Real-time processing of contrast-limited adaptive histogram equalization on FPGA. (FPL), 2010, p. 157–158.
51. Ali Reza. «Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for Real-Time Image Enhancement.» VLSI Signal Processing v. 2004, pp. 35–44.
52. Chengwei Liu, Xiubao Sui. Optimized Contrast Enhancement for Infrared Images Based on Global and Local Histogram Specification, April 2019 Remote Sens. 2019, 11, 849, pp.1-21.
53. M. Wan, G. Gu, W. Qian, K. Ren, Q. Chen and X. Maldague, Infrared Image Enhancement Using Adaptive Histogram Partition and Brightness Correction, Remote Sensing, vol.10, no. 5, May. 2018.
54. M. Wan, G. Gu, W. Qian, K. Ren, Q. Chen and X. Maldague, Infrared Image Enhancement Using Adaptive Histogram Partition and Brightness Correction, Remote Sensing, vol.10, no. 5, May. 2018.

55. Ana Bel'en Petro, Catalina Sbert, Jean-Michel Morel, Multiscale Retinex, Image Processing On Line, 4 (2014), pp. 71–88.
56. Ferguson P. D. Evaluation of Contrast Limited Adaptive Histogram Equalization (CLAHE) Enhancement on a FPGA. Alba Campus. Livingston, 2008. Pp. 10-18.
57. Moroney N. Local color correction using non-linear masking // IS&T/SID Eight Color Imaging Conference, 2000. Pp. 108–111.
58. Грицкевич И.Ю. Гибридный метод локального контрастирования изображений с нейросетевой регулировкой параметров // Труды учебных заведений связи. 2025. Т. 11. № 2. С. 26–33. DOI:10.31854/1813-324X-2025-11-2-26-33. EDN:TKAPTM.
59. Грицкевич И. Ю., Тикменов В.Н., и др. Алгоритм автоматической локальной эквализации зон, окружающих каждый пиксель изображения на языке описания аппаратуры интегральных схем Свидетельство о регистрации программы для ЭВМ 2021661277, 08.07.2021. Заявка № 2021617186 от 13.05.2021.
60. Грицкевич И. Ю., Ерганжиев Н. А. Алгоритм адаптивного контрастирования с учетом локальных сюжетных особенностей изображения. // Актуальные проблемы радио- и кинотехнологий, 2021, с. 36.
61. Грицкевич И. Ю., Ерганжиев Н. А., Григорьев Д. С. Реализация метода локального контрастирования изображений на плис Вопросы радиоэлектроники. // Серия: Техника телевидения. 2019. № 4. С. 78-83.
62. Грицкевич И.Ю., Ерганжиев Н.А. Алгоритм адаптивного контрастирования с учетом локальных сюжетных особенностей изображения // V Международная научно-техническая конференция, посвященная 140-летию со дня рождения выдающегося физика и создателя первой русской усилительной радиолампы Н.Д. Папалекси «Актуальные проблемы радио и кинотехнологий» (Санкт-Петербург, Россия, 24–25 ноября 2020).СПб.: Санкт-Петербургский государственный институт кино и телевидения, 2021. С. 36–40.
63. Красильников Н.Н. Цифровая обработка 2D-и 3D-изображений. СПб.: БХВ-Петербург, 2011. 608 с.

64. Сифоров В.И., Ярославский Л.П. Адаптивные методы обработки изображений. М.: Наука, 1988. 248 с.
65. Умбиталиев А.А., Цыцулин А.К., Левко Г.В., Пятков В.В., Кузичкин А.В., Дворников С.В. и др. Теория и практика космического телевидения. СПб: АО «НИИ телевидения», 2017.— Suckling J., Parker J., Dance D., Astley S., Hutt I., Boggis C., et al. The mammographic Image Analysis Society Digital Mam-mogram Database // Excerpta Medica. International Congress Series. 1994. Vol. 1069. PP. 375–378.
66. H. R. Sheikh, A. C. Bovik, and G. De Veciana, “An information fidelity criterion for image quality assessment using natural scene statistics,” IEEE Trans. Image Process., vol. 14, no. 12, Dec. 2005. Pp. 2117–2128.
67. Wang Z., Simoncelli E.P. Translation insensitive image similarity complex wavelet domain // IEEE Inter. Conf. Acoustic, Speech and Signal Processing. 2005. V. 2. P. 673—676.
68. A. Mittal, A. K. Moorthy and A. C. Bovik, “Blind/Referenceless Image Spatial Quality Evaluator”, 2011, Conference Record of the Forty Fifth Asilomar Conference on Signals, Systems and Computers (ASILOMAR), Pacific Grove, CA, USA, 2011, pp. 723-727, doi:10.1109/ACSSC.2011.6190099.
69. Грицкевич И. Ю., Гоголь А. А. Алгоритм безэталонной оценки качества изображений Труды учебных заведений связи Т10 №2 2024.
70. Cybenko G. Approximation by superpositions of a sigmoidal function // Mathematics of Control, Signals and Systems. 1989. Vol. 2. PP. 303–314. DOI:10.1007/bf02551274.
71. Грицкевич И. Ю., Ерганжиев Н. А., Жарков В. И. Адаптивное контрастирование с учетом локальных сюжетных особенностей ИК-изображений. В сборнике: Подготовка профессиональных кадров в магистратуре для цифровой экономики (ПКМ-2020). Региональная научно-методическая конференция магистрантов и их руководителей. Сборник лучших докладов конференции. Сост. Н.Н. Иванов. Санкт-Петербург, 2021. С. 65-69.
72. Грицкевич И. Ю., Виноградов А. С., Григорьев Д. С., Петров М. Н. Улучшение качества потоковых изображений в реальном времени методом CLANE.

// Вестник Новгородского государственного университета. 2017. № 6 (104). С. 20-23.

73. Грицкевич И. Ю., Мичурин Р. А., Филиппов А. В. Роботизированный контрольный комплекс с функцией определения гироскопического азимута и технологией дополненной реальности. // Электронные информационные системы. 2(29), 2021, с 49-55.

74. Грицкевич И. Ю., Котухов А.А. Робототехнический комплекс укладки газобетона Патент на изобретение №RU (11) 2 803 337 (13) С1 , Заявка № 2022125196 от 26.09.2022.

75. Грицкевич И. Ю., Мичурин Р.А., Филлипов А.В. Программное обеспечение автоматизированного навигационного комплекса с технологией дополненной реальности Свидетельство о регистрации программы для ЭВМ 2021661328, 08.07.2021. Заявка № 2021660484 от 02.07.2021.

76. Грицкевич И. Ю., Ерганжиев Н. А., Жарков В. И. Установление начальных параметров локального контрастирования при автоматической обработке цветных изображений автомобильного потока. Электронные информационные системы № 2 (29) 2021. С. 73—79.

77. Устройство для получения и стабилизации тепловизионного изображения. Патент на полезную модель RU 199927 U1 29.09.2020. Грицкевич И.Ю., Удальцов В.Е., Мазуров А.С., Осетров А.А.

78. Автомат регулировки экспозиции на языке описания аппаратуры интегральных схем. Свидетельство о регистрации программы для ЭВМ RU 2016611835 11.02.2016. Грицкевич И. Ю.

79. Устройство электронной обработки тепловизионных изображений Патент на полезную модель RU 199927 U1 29.09.2020. Грицкевич И.Ю., Малютов А.Г., и др.

80. Грицкевич И. Ю., Ерганжиев Н. А. Результаты применения выборочных параметров локального контрастирования для отдельных частей изображения. Международная научная конференция по проблемам управления в технических системах, 2019. Т. 1. С. 271-274.

81. Грицкевич И.Ю. Алгоритмы управления временем экспозиции видеокамер. НовГУ, Великий Новгород. Тезисы докладов «Микроэлектроника и информатика - 2015», 22-я Всероссийская межвузовская научно-техническая конференция студентов и аспирантов МИЭТ, г. Москва, г. Зеленоград

82. Грицкевич И. Ю. Методы определения выдержки для светочувствительной матрицы видеокамеры / И. Ю. Грицкевич. — Текст : непосредственный // Молодой ученый. — 2016. — № 17 (121). — С. 1-4. — URL: <https://moluch.ru/archive/121/33571/>

83. Грицкевич И. Ю., Телина И. С. Оценка алгоритмов управления временем экспозиции. // Вестник Новгородского государственного университета. 2016. № 7 (98). С. 6-12.

84. Грицкевич И. Ю. Автомат регулировки экспозиции на языке описания аппаратуры интегральных схем Свидетельство о регистрации программы для ЭВМ RU 2016611835, 11.02.2016. Заявка № 2015662545 от 17.12.2015.

ПРИЛОЖЕНИЯ

Приложение 1

УТВЕРЖДАЮ
1-й заместитель - заместитель
генерального директора по НИОКР
АО «ЦКБ «ФОТОН»
Ф.М. Броун
«13» / 11 2024 г.



АКТ РЕАЛИЗАЦИИ

Комиссия в составе:

- председателя – главного конструктора направления АО «ЦКБ «ФОТОН» Седова В.М.;

членов комиссии:

- заместителя начальника конструкторского отдела Старостина А.В.;

- руководителя группы электроники Кузнецова В.И.;

- инженера - конструктора 1 категории Филиппова А.В.

составила настоящий акт о том, что научные результаты диссертационной работы Грицкевича И.Ю. «Разработка методов реализации и обработки малоконтрастных изображений в условиях ограниченной видимости» были использованы при формировании научно-технического задела для последующего проведения НИОКР по разработке приборов наблюдения и разведки нового поколения.

Разработанный алгоритм оценки контраста изображений позволит снизить количество артефактов и зависимость результатов оценки от уровня шума, как для всего изображения, так и для его деталей ориентировочно в 2 раза.

Председатель комиссии

члены комиссии:

В.М. Седов
А.В. Старостин
В.И. Кузнецов
А.В. Филиппов



Приложение 2


**КРАСНОГОРСКИЙ ЗАВОД
им. С.А. ЗВЕРЕВА**

Публичное акционерное общество
«Красногорский завод им. С.А. Зверева»
(ПАО КМЗ)

143403, Московская область,
г. Красногорск, ул. Речная, 8
Т.: +7 (495) 561 80 08
Ф.: +7 (495) 561 26 32
e-mail: kmz@zenit-kmz.ru
www.zenit-kmz.com

ОКПО 07526142
ОГРН 1025002863247
ИНН/КПП 5024022965/774550001

от _____ № _____
на № _____ от _____

УТВЕРЖДАЮ

Директор НТЦ,
кандидат технических наук
Н.В. Тышкун

« 28 » _____ 2024 г.



АКТ

внедрения результатов диссертационной работы Грицкевича Ивана Юрьевича на тему:
«Исследование и разработка методов реализации и обработки малококонтрастных изображений в
условиях ограниченной видимости», представленной на соискание ученой степени кандидата
технических наук по специальности 05.12.04 – Радиотехника, в том числе системы и устройства
телевидения.

Комиссия в составе:

1. Заместитель директора НТЦ по проектно-конструкторскому обеспечению – Беляев К.С.;
2. Заместитель директора НТЦ по научным исследованиям и разработкам – Модель С.С.;
3. Начальник тематического отдела обзорно-прицельных систем армейской авиации – Гук А.С.;
4. Главный специалист департамента технической документации и систем обеспечения ЖЦИ – Никитин С.М.

Составила настоящий акт о том, что результаты диссертационной работы Грицкевича И.Ю. по теме: «Исследование и разработка методов реализации и обработки малококонтрастных изображений в условиях ограниченной видимости» были внедрены в рамках проекта ТВК-294 в изделия ОПС-28 ПАО «Красногорский завод им. С.А. Зверева». Внедрение позволило получить следующие результаты:

- Усовершенствованный метод оценки качества изображений позволил повысить достоверность результатов анализа и снизить вероятность ошибки;

- Алгоритмы работы с датчиком, адаптированные к условиям ограниченной видимости, позволили добиться улучшения анализа и повышения точности надежности работы системы. Конкретные данные о приросте точности и надежности являются коммерческой тайной;

- В результате внедрения разработок значительно повысилась точность обработки изображений и снизилось время реакции системы. Точные количественные данные являются конфиденциальными

Полученные результаты разработки имеют практическую ценность и могут быть применены при разработке других перспективных изделий ПАО КМЗ.

Члены комиссии

Беляев К.С.

Модель С.С.

Гук А.С.

Никитин С.М.

Приложение 3



АКТ

о внедрении результатов диссертационной работы
Грицкевича Ивана Юрьевича
на тему

«Исследование и разработка методов реализации и обработки
малоконтрастных изображений в условиях ограниченной видимости»

Комиссия в составе: председателя заместителя начальника конструкторского бюро – директора направления вооружения БТТ, ПТРК и роботизированных комплексов Боровых О. А., членов комиссии заместителя главного конструктора по комплексам вооружения бронетанковой техники и начальника отделения Парфенова Д. В., начальника отделения Чинарева А. В. – составила настоящий акт о том, что в АО «КБП» при проведении опытно-конструкторских работ по разработке телевизионных каналов ТК-1 (тема «Бумеранг») и ТК-4 (тема «Эпоха») внедрены следующие результаты диссертационной работы Грицкевича И. Ю.

Внедренные результаты:

1. Алгоритм контрастирования с применением элементов искусственного интеллекта в ПЛИС, позволивший 6-кратно увеличить количество распознаваемых объектов при 20-кратном уменьшении времени обработки изображений.

2. Алгоритм оценки качества малоконтрастных изображений в условиях ограниченной видимости, позволивший улучшить как качество оценки изображений, так и обеспечить задаваемую точность его контрастирования.

Председатель комиссии:


/ О. А. Боровых /

Члены комиссии:


/ Д. В. Парфенов /


/ А. В. Чинарев /

Приложение 4



18 декабря 2024 г. №

УТВЕРЖДАЮ
Генеральный директор
АО «Научно-технический центр ЭЛИНС»,
доктор технических наук

В.Н. Тикменов
2024 г.

АКТ

внедрения результатов диссертационной работы Грицкевича Ивана Юрьевича на тему «Исследование и разработка методов реализации и обработки малоконтрастных изображений в условиях ограниченной видимости», представленной на соискание ученой степени кандидата технических наук по специальности 05.12.04 - Радиотехника, в том числе системы и устройства телевидения.

Комиссия НТС в составе:

1. Первый заместитель главного конструктора к.т.н. В.И. Ухандеев
2. Заместитель главного конструктора О.Н. Рубичев
3. Заместитель главного конструктора А.С. Леонтьев
4. Заместитель главного конструктора И.В. Варакин

Составили настоящий акт о том, что результаты диссертационной работы Грицкевича И.Ю. по теме «Исследование и разработка методов реализации и обработки малоконтрастных изображений в условиях ограниченной видимости» внедрены в рамках проведенных НИОКР и военно-технического эксперимента, получены следующие результаты:

- снизилась зависимость оценки изображения от шумов различного происхождения, что значительно улучшило качество анализа и увеличило точность распознавания объектов до двух раз;
- обеспечена настройка точности контрастирования деталей изображения в зависимости от сюжетной составляющей изображения;
- уменьшена зависимость оценки контраста от уровня шума в два раза, тем самым существенно улучшилось качество анализа изображений в процессе автоматической обработки изображений оптико-электронной системы;
- повышен контраст отдельных частей изображения не меняя соотношение яркости во всем кадре;
- в ходе эксперимента по имитации поисково-спасательных работ в лесной местности в зимний период в условиях ограниченной видимости (ночное время, плотные кроны деревьев, туман, снегопад) за период с 10.01.2024 по 24.03.2024 применен разработанный Грицкевичем И.Ю. алгоритм обработки малоконтрастных ИК-изображений. Алгоритм интегрирован в систему обработки данных, получаемых с тепловизора. Количество обнаруженных людей за один цикл поиска в среднем увеличилось с 1 до 4, что соответствует четырехкратному увеличению эффективности.

Полученные результаты разработки имеют практическую ценность и приняты к реализации при разработке системы «Арбалет ДМ», внедрены при анализе изображений в рамках СЧ ОКР «Эвакуация-Р-Элинс», в оптико-электронном комплексе «Станция тепло-телевизионная» и в прицельном комплексе в составе перспективной зенитной установки, а также могут быть применены при разработке других перспективных систем управления и оптико-электронных средств в АО «НТЦ ЭЛИНС».

Секретарь НТС



в.н.с., к.т.н.
И.В. Дорогавцев

Члены НТС



Первый заместитель главного
конструктора к.т.н.
В.И. Ухандеев



Заместитель главного конструктора
О.Н. Рубичев



Заместитель главного конструктора
А.С. Леонтьев



Заместитель главного конструктора
И.В. Варакин